



Contribution au pronostic de défaillances guidé par des données

Kamal Medjaher

► To cite this version:

Kamal Medjaher. Contribution au pronostic de défaillances guidé par des données. Sciences de l'ingénieur [physics]. Université de Franche-Comté, 2014. tel-01286652

HAL Id: tel-01286652

<https://hal.science/tel-01286652>

Submitted on 11 Mar 2016

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

HABILITATION À DIRIGER DES RECHERCHES

présentée à

L'UNIVERSITÉ DE FRANCHE-COMTÉ

École Doctorale Sciences Physiques pour l'Ingénieur et Microtechniques

Contribution au pronostic de défaillances guidé par des données

par

Kamal MEDJAHÉ

Maître de Conférences à l'École Nationale Supérieure de Mécanique et des Microtechniques

Soutenue le 11 décembre 2014 devant la Commission d'Examen :

Rapporteurs

Christophe Bérenguer	Professeur à l'Institut Polytechnique de Grenoble
José Ragot	Professeur émérite à l'Université de Lorraine
Kamal Youcef-Toumi	Professeur au Massachusetts Institute of Technology

Examineurs

Nicolas Chaillet	Professeur à l'Université de Franche-Comté
Belkacem Ould Bouamama	Professeur à l'École Polytechnique de Lille
Robert Plana	Directeur de la R&D et des relations Universitaires, Groupe Alstom
Noureddine Zerhouni	Professeur à l'École Nationale Supérieure de Mécanique et des Microtechniques

À mes parents
À mon épouse Ferroudja et mes filles Inès et Ania
À toute ma famille

Remerciements

Je remercie tout particulièrement le Professeur Nouredine Zerhouni pour m’avoir accueilli dans son équipe de recherche et pour m’avoir proposé de travailler sur la thématique du « Prognostics and Health Management (PHM) » qu’il a initiée au sein de l’Institut FEMTO-ST. Je le remercie pour sa confiance, son soutien, ses conseils avisés, ses critiques constructives et objectives et pour toutes les discussions scientifiques que nous avons eues tout au long de mes travaux de recherche. Ces travaux n’auraient pas pu être réalisés sans son implication directe et régulière. Je voudrais lui témoigner toute ma gratitude.

Je remercie vivement Christophe Bérenguer, Professeur à Grenoble INP, José Ragot, Professeur à l’Université de Lorraine, et Kamal Youcef-Toumi, Professeur au Massachusetts Institute of Technology, pour m’avoir fait l’honneur de rapporter sur les travaux présentés dans ce mémoire et ce en dépit de leurs agendas chargés.

Je remercie chaleureusement Nicolas Chaillet, Directeur de l’Institut FEMTO-ST et Professeur à l’Université de Franche-Comté, Belkacem Ould Bouamama, Professeur à l’École Polytechnique de Lille, Robert Plana, Directeur de la R&D et des relations Universitaires du Groupe Alstom, et Nouredine Zerhouni, Professeur à l’École Nationale Supérieure de Mécanique et des Microtechniques, pour l’intérêt qu’ils portent à ces travaux et pour avoir accepté de les examiner.

Je remercie tous les personnels de l’ENSMM, du département AS2M et de l’institut FEMTO-ST pour l’excellente ambiance de travail, les échanges quotidiens et l’aide précieuse apportée tout au long de la réalisation de ces travaux de recherche, d’encadrement et d’enseignement.

Je remercie tout particulièrement les stagiaires, les doctorant(e)s et les post-doctorants avec qui j’ai eu le plaisir de travailler et sans lesquels ces travaux ne seraient pas aboutis. Je remercie également mes collègues de l’équipe PHM pour les échanges scientifiques et les discussions fructueuses que nous avons eues depuis ma prise de fonction de Maître de Conférences.

Enfin, je remercie ma famille pour son soutien indéfectible tout au long de mon parcours et lors de la préparation et rédaction de ce mémoire. Je remercie tout particulièrement mon épouse Ferroudja pour son soutien et ses encouragements quotidiens. Sans elle, je n’aurais sans doute pas accompli les travaux présentés dans ce mémoire.

Table des matières

Introduction	1
I CV, résumé des activités de recherche, d'encadrement et d'enseignement	3
Curriculum Vitæ	5
1 État civil	5
2 Poste actuel	5
3 Formations et diplômes	6
4 Expériences professionnelles	6
Résumé des activités de recherche	7
1 Travaux liés à la thèse	7
2 Travaux en qualité d'ATER	8
3 Publications liées aux travaux de thèse	8
4 Travaux de recherche en qualité de Maître de Conférences	9
4.1 Choix des composants critiques et acquisition de données	11
4.2 Extraction de caractéristiques et construction d'indicateurs de santé . . .	11
4.3 Modélisation de dégradations	12
4.4 Évaluation de l'état de santé et prédiction du RUL	13
4.5 Applications	14
4.6 Publications postdoctorales	14
5 Insertion dans l'équipe de recherche	17
5.1 Encadrement de travaux de recherche	17
5.1.1 Encadrement de post-doctorants	17
5.1.2 Encadrement de thèses	18
5.1.3 Masters 2 Recherche et Projets de Fin d'Études	18
5.2 Évaluation de travaux de recherche	19
5.2.1 Jurys de thèses	19
5.2.2 Relecture d'articles de revues	19
5.2.3 Relecture de chapitres de livres	19
5.2.4 Relecture d'articles de conférences	19
5.3 Rayonnement scientifique	20
5.3.1 Comités d'organisation de conférences	20
5.3.2 Organisation d'un data challenge en PHM	20
5.3.3 Invitations, séjours et séminaires scientifiques	20
5.3.4 Présentations au sein du Groupe de Travail S3 du GdR MACS .	21
5.4 Fonctions scientifiques et administratives	21

5.5	Responsabilités exercées dans des projets liés à la recherche	22
Activités d'enseignement		23
II Synthèse des activités de recherche		25
Introduction générale		27
1	Contexte/Motivation	27
2	État de l'art	28
3	Positionnement scientifique	32
4	Challenges, problématiques et verrous scientifiques	34
5	Cadre général et hypothèses de travail	36
6	Principales contributions	37
7	Organisation de la partie activités de recherche	38
1	Choix des composants critiques et acquisition de données	39
1	Introduction	39
2	Choix des composants critiques	40
2.1	Retour d'expérience	41
2.2	AMDEC	42
2.3	Arbre de défaillances	43
3	Grandeurs physiques à surveiller	43
4	Acquisition et stockage de données	44
4.1	Capteurs	45
4.1.1	Types de capteurs	45
4.1.2	Choix des capteurs	46
4.2	Acquisition, prétraitement et stockage de données	47
5	Cas d'étude	49
6	La plateforme expérimentale Pronostia	50
6.1	Principe de fonctionnement	51
6.2	Expérimentations réalisées	52
6.3	Exemples de signaux obtenus	53
7	Conclusion	54
2	Traitement de données	57
1	Introduction	57
2	Extraction de caractéristiques	59
2.1	Caractéristiques temporelles	60
2.2	Caractéristiques fréquentielles	61
2.3	Caractéristiques temps-fréquence	62
2.3.1	Transformée de Fourier à court terme	62
2.3.2	Décomposition en paquets d'ondelettes	63
2.3.3	Décomposition modale empirique	64
2.3.4	Transformée de Hilbert-Huang	66
3	Réduction de caractéristiques	68
3.1	Méthode linéaire : analyse en composantes principales	68
3.2	Méthodes non linéaires	71
3.2.1	ACP à noyau	71
3.2.2	ISOMAP	73

4	Sélection de caractéristiques	75
5	Construction d'indicateurs de santé	75
5.1	Indicateurs de santé obtenus par sélection - réduction et EMD	77
5.2	Indicateurs de santé générés en utilisant la transformée de Hilbert-Huang	77
6	Conclusion	80
3	Modélisation de la dégradation	83
1	Introduction	83
2	Réseaux Bayésiens dynamiques	85
2.1	Chaînes de Markov cachées	85
2.2	Chaînes de Markov cachées à mélange de Gaussiennes	90
2.3	Réseaux Bayésiens Dynamiques	91
2.4	Représentation des HMMs et des MoG-HMMs par des RBDs	92
2.5	Choix des paramètres des modèles MoG-HMMs et RBDs	95
3	Séparateurs à vaste marge pour régression	96
3.1	Séparateurs à vaste marge	96
3.2	Séparateurs à vaste marge pour régression	98
3.3	Choix du paramètre η	100
4	kNN et GPR	101
4.1	kNN	101
4.2	Processus de Gauss pour la régression	103
5	Conclusion	105
4	Évaluation de l'état de santé et prédiction du RUL	107
1	Introduction	107
2	Approche utilisant les MoG-HMMs et les RBDs	109
2.1	Application aux roulements	113
2.2	Application à l'usure des outils de coupe	118
3	Approche utilisant le processus de Gauss pour la régression	123
3.1	Application aux turboréacteurs	124
3.2	Application aux batteries Lithium-Ion	126
4	Approche utilisant les SVRs	129
4.1	Phase hors ligne	129
4.2	Phase en ligne	130
4.3	Application	132
5	Conclusion	136
	Conclusion et perspectives	137
1	Conclusions	137
2	Perspectives	138
2.1	Pronostic de défaillances de systèmes complexes	138
2.2	Pronostic de défaillances des MEMS	140
2.3	Décision	142
2.4	Transferts industriel et académique	143
	Bibliographie	145

Table des figures

1	Processus générique du PHM.	9
2	Pronostic orienté composants et guidé par les données.	10
1	Modules du PHM.	28
2	Diagnostic vs pronostic.	29
3	Approches de pronostic de défaillances.	31
4	Principe du pronostic basé sur un modèle physique.	31
5	Principe du pronostic guidé par les données.	32
6	Pronostic orienté composants et guidé par les données.	37
7	Principales contributions et publications associées.	37
1.1	Étapes de la démarche proposée.	39
1.2	Exemple de composants critiques.	40
1.3	Étapes suivies pour le choix des composants critiques.	41
1.4	Structure d'une chaîne d'acquisition [9].	45
1.5	Exemples de capteurs de force et d'accéléromètres à quartz.	46
1.6	Structure simplifiée et illustrée d'une chaîne d'acquisition.	47
1.7	De gauche à droite : carte d'acquisition de vibrations, de température et châssis externe à l'ordinateur.	47
1.8	Exemples de formats de fichiers de données : à gauche un format .csv, à droite un format .xlsx.	48
1.9	Sous-systèmes d'un train.	49
1.10	Composants critiques d'un moteur de train.	49
1.11	Banc d'expérimentation de roulements Pronostia.	51
1.12	Éléments du banc permettant d'appliquer la contrainte radiale.	51
1.13	Système de démultiplication et de transmission de la charge.	52
1.14	Exemples de dégradations	53
1.15	Exemple de signaux vibratoires bruts obtenus de la plateforme Pronostia.	53
2.1	Signal vibratoire obtenu de la plateforme Pronostia.	57
2.2	Extraction, sélection et réduction de caractéristiques et construction d'indicateurs de santé.	58
2.3	Techniques d'extraction de caractéristiques [171].	59
2.4	Exemples de caractéristiques temporelles obtenues sur des signaux vibratoires : à gauche le carré de la moyenne quadratique (RMS) et à droite le Kurtosis.	61
2.5	Transformée de Fourier rapide obtenue à partir du signal vibratoire d'une durée de 3h25.	62
2.6	Résultat de la transformée de Fourier à court terme réalisée sur un signal de vibration.	63
2.7	Exemple de décomposition en paquets d'ondelettes.	64

2.8	Pourcentage d'énergie du signal de l'accéléromètre vertical (1) pour les tests réalisés sous la condition numéro 1, après la décomposition en paquets d'ondelettes.	64
2.9	Signal $x(t)$ et ses enveloppes supérieure et inférieure.	66
2.10	La première IMF extraite.	66
2.11	Processus de décomposition en IMFs.	67
2.12	Variation du résidu de l'EMD en fonction de l'état du composant.	67
2.13	Exemples de résultats obtenus sur des signaux vibratoires issus de la plateforme Pronostia.	69
2.14	Méthodes de réduction de données.	70
2.15	Principe de l'analyse en composantes principales.	70
2.16	Réduction de trois à deux dimensions en utilisant l'ACP.	71
2.17	Principe de l'ACP à noyau, d'après [19].	71
2.18	Résumé de la démarche de l'astuce du noyau.	72
2.19	Résultat d'une ACP à noyau sur des données prises de Pronostia.	73
2.20	Illustration des étapes de l'Isomap, d'après [141] : (A) distance géodésique entre deux points, (B) graphe de voisinage et approximation de la distance géodésique par le chemin le plus court entre les deux points sur le graphe, (C) projection des données dans un espace de dimension 2 où la distance géodésique est maintenant approximée par la ligne droite.	74
2.21	Extraction de deux, puis d'une caractéristique à partir du Kurtosis, du RMS et de l'écart type en utilisant l'Isomap.	74
2.22	Dendrogramme obtenu à partir du partitionnement sur les distances de similarité par paire.	76
2.23	Exemple de deux groupes de caractéristiques : à gauche une forte corrélation entre trois variables et à droite une faible corrélation entre deux variables.	76
2.24	Construction d'indicateurs de santé par sélection - réduction - EMD.	77
2.25	Indicateurs de santé obtenus sur des données de la plateforme Pronostia.	78
2.26	Indicateurs de santé obtenus sur des données de la NASA [143].	78
2.27	Démarche de construction d'indicateurs de santé en utilisant la transformée de Hilbert-Huang.	79
2.28	Illustration de la sélection des IMFs.	79
2.29	Indicateurs de santé obtenus en utilisant la transformée de Hilbert-Huang.	80
3.1	Transformation des données de surveillance en modèles.	83
3.2	Données d'entrée des outils de modélisation utilisés.	84
3.3	Phases de la démarche de modélisation.	85
3.4	Classification des processus de Markov	86
3.5	Exemple d'une chaîne de Markov discrète.	86
3.6	Chaîne de Markov cachée (HMM).	87
3.7	Représentation d'un processus stochastique de Markov par RB et RBD	91
3.8	Représentation d'un HMM par un RBD déroulé sur 3 instants.	92
3.9	Représentation d'un HMM par un RBD	93
3.10	Représentation d'un MoG-HMM par un RBD	93
3.11	Étude de sensibilité pour déterminer le nombre de mélanges M .	95
3.12	Représentation multi-dimensionnelle et matricielle des indicateurs de santé.	96
3.13	Principe de classification par SVM.	97
3.14	Principe du séparateur à marge souple.	97
3.15	Principe simplifié du SVR.	98
3.16	Principe du SVR.	99

3.17	Intégration des outils kNN et GPR.	101
3.18	Recherche des indicateurs de santé (Health Indicators : HI) les plus proches des classes apprises hors ligne.	102
3.19	L'estimation du RUL par le kNN peut conduire à des erreurs élevées.	103
3.20	Relation entre les entrées (indicateurs de santé hors ligne) et les sorties correspondantes (EOL).	103
4.1	Initiation et évolution d'une dégradation.	107
4.2	Évolution de l'état de santé du composant : représentation par un ensemble de caractéristiques (à gauche) et par un indicateur de santé (à droite).	108
4.3	Illustration du RUL.	108
4.4	Pronostic de défaillances basé sur l'utilisation de RBDs.	109
4.5	Exemple de séquence d'états obtenue par l'algorithme de Viterbi.	111
4.6	Sélection du meilleur modèle représentant les observations courantes.	111
4.7	Définition des chemins court et long.	112
4.8	Exemples de caractéristiques extraites de l'accéléromètre radial	114
4.9	Pourcentages d'énergie extraits de l'accéléromètre vertical en utilisant la WPD.	114
4.10	Analyse de sensibilité pour déterminer le nombre de mélanges M	115
4.11	Séquence d'états obtenue en utilisant l'algorithme de Viterbi sur l'historique 1.	115
4.12	Estimation du RUL pour l'historique 2.	117
4.13	Le banc d'essai d'usinage [145].	118
4.14	Les résultats de clustering.	119
4.15	Séquence d'états pour un historique d'évolution de l'usure.	120
4.16	Séquence d'états.	121
4.17	Résultats de simulation	122
4.18	Approche de pronostic basée sur le k-NN et le processus de Gauss pour la régression.	123
4.19	Résultat de la sélection de variables et exemple d'indicateur de santé obtenu pour le turboréacteur numéro 61.	125
4.20	Résultats de prédiction des RULs pour les quatre turboréacteurs.	126
4.21	Résultat de la sélection de variables et exemple d'indicateur de santé obtenu pour la batterie B0005.	128
4.22	Résultats de prédiction du RUL pour 2 batteries.	128
4.23	Approche de pronostic basée sur les SVRs.	130
4.24	Apprentissage des modèles SVRs et estimation du RUL.	131
4.25	Évolution des indicateurs de santé en fonction de la dégradation du roulement numéro 4.	133
4.26	États de dégradation du roulement numéro 4.	134
4.27	Détection de l'état de dégradation des roulements 1 à 3.	134
4.28	Estimation des RULs des éléments constitutifs du roulement 1.	135

Introduction

Ce mémoire résume mes activités de recherche, d'encadrement et d'enseignement. Ces activités concernent les périodes de thèse, d'Attaché Temporaire d'Enseignement et de Recherche (ATER) et de Maître de Conférences.

J'ai effectué ma thèse de septembre 2002 à juillet 2005 au sein du Laboratoire d'Automatique, Génie Informatique et Signal (LAGIS) de Lille, anciennement appelé Laboratoire d'Automatique et d'Informatique de Lille (LAIL), après un stage de DEA (Diplôme des Études Approfondies) de six mois. Durant cette période, j'ai travaillé sur la détection et le diagnostic automatique de défaillances des systèmes multi-physiques (processus thermofluides). Mes travaux ont alors porté sur l'utilisation d'une approche quantitative basée sur des modèles de comportement dynamiques obtenus en utilisant l'outil bond graph. Ces modèles permettent de générer des relations de redondance analytique et des résidus. Ces derniers sont ensuite exploités pour détecter en ligne d'éventuelles défaillances et localiser les causes.

Après la thèse, j'ai occupé pendant une année un poste d'ATER au sein du même laboratoire où j'ai continué à travailler sur le diagnostic automatique de défaillances appliqué aux systèmes mécatroniques.

À la fin de la période d'ATER, j'ai rejoint le premier septembre 2006 l'École Nationale Supérieure de Mécanique et des Microtechniques (ENSMM) en qualité de Maître de Conférences, section 61, pour assurer les deux missions principales de tout enseignant-chercheur que sont l'enseignement et la recherche. Depuis, je réalise ma fonction enseignement à l'ENSMM et ma fonction recherche au sein de l'équipe « Prognostics and Health Management (PHM) » du département Automatique des Systèmes Micro-Mécatroniques (AS2M) de l'institut FEMTO-ST.

Mon passage de l'Université des Sciences et Technologies de Lille (Laboratoire LAGIS) à l'ENSMM (Institut FEMTO-ST) témoigne de ma mobilité à la fois géographique et thématique. En effet, après des travaux réalisés dans le domaine du diagnostic automatique de défaillances au LAGIS, j'ai eu comme projet de recherche à mon arrivée à l'institut FEMTO-ST de développer et consolider la nouvelle thématique de PHM créée par le Professeur Nouredine Zerhouni. Cette mobilité thématique s'est également accompagnée de changements d'approche et d'outils de formalisation. En effet, je suis passé d'une approche quantitative à base de modèles physiques à une approche guidée par des données faisant appel à des outils issus du domaine de l'intelligence artificielle.

Ce mémoire comporte deux parties. La première partie présente mon curriculum vitae et résume l'ensemble de mes activités de recherche, d'encadrement et d'enseignement. La seconde partie traite de nos contributions scientifiques et du projet de recherche.

Première partie

CV, résumé des activités de recherche,
d'encadrement et d'enseignement

Curriculum Vitæ

1 État civil

Kamal MEDJAHÉ

Né le 23 juillet 1974 à Maâtkas, Algérie

Marié, 2 enfants

Adresse personnelle :

6 C rue de la famille
25000, Besançon, France

Adresse professionnelle :

École Nationale Supérieure de Mécanique et des Microtechniques (ENSMM)
Département AS2M de l'institut FEMTO-ST
24, rue Alain Savary
25000, Besançon
Tél. : +33 (0)3 81 40 27 96
Fax : +33 (0)3 81 40 28 09
E-mail : kamal.medjaher@ens2m.fr

2 Poste actuel

Maître de Conférences

Date de recrutement : 01 septembre 2006

Enseignement : École Nationale Supérieure de Mécanique et des Microtechniques de Besançon

Recherche : Département d'Automatique des Systèmes Micro-Mécatroniques (AS2M) de l'institut FEMTO-ST

Équipe : Prognostics and Health Management (PHM)

Thématiques de recherche : Traitement de données, Surveillance, Détection, Diagnostic et Prognostic de défaillances

3 Formations et diplômes

- Septembre 2002 - Juillet 2005 : Docteur de l'Université des Sciences et Technologies de Lille.
Spécialité : Automatique et Informatique Industrielle.
Titre de la thèse : Contribution de l'outil bond graph pour la conception de systèmes de supervision des processus industriels.
Laboratoire d'accueil : Laboratoire d'Automatique, Génie Informatique et Signal (LAGIS).
Directeur de thèse : Prof. Belkacem Ould Bouamama.
Co-encadrant : Dr. Arun Kumar Samantaray.
Jury : Prof. José Ragot (rapporteur), Prof. Kamal Youcef-Toumi (rapporteur), Prof. Geneviève Dauphin-Tanguy, Prof. Jean-Charles Cadiou, Dr. Bertrand Braunschweig.
- Septembre 2001 - Juin 2002 : DEA en Automatique et Informatique Industrielle.
Établissement : Université des Sciences et Technologies de Lille - École Centrale de Lille.
- 1992 - 1998 : Ingénieur d'état en électronique, option contrôle.
Établissement : Université M. Mammeri, Tizi-Ouzou (Algérie).
- Juin 1992 : Baccalauréat série Mathématiques (C).

4 Expériences professionnelles

- Depuis septembre 2006 : Maître de Conférences à l'École Nationale Supérieure de Mécanique et des Microtechniques de Besançon (ENSMM).
- Septembre 2005 - Août 2006 : Attaché Temporaire d'Enseignement et de Recherche à l'Université des Sciences et Technologies de Lille.
- Septembre 2004 - Août 2005 : Attaché Temporaire d'Enseignement et de Recherche à l'école d'ingénieurs Polytech'Lille.
- Septembre - Octobre 2003 : Enseignant vacataire à Polytech'Lille.
- Septembre 1999 - Mars 2001 : Service national.
- Novembre 1998 - Février 1999 : Ingénieur chez Alpha Technologies, Alger.

Résumé des activités de recherche

1 Travaux liés à la thèse

J'ai réalisé ma thèse dans le cadre du projet Européen CHEM¹, au sein du thème transversal « Bond Graph - Surveillance » entre les équipes « Bond Graph » et « Sécurité de Fonctionnement des Systèmes Dynamiques (SFSD) » du Laboratoire d'Automatique, Génie Informatique et Signal (LAGIS) de l'Université des Sciences et Technologies de Lille.

L'objectif de la thèse était la conception d'un système de supervision à base de modèles quantitatifs utilisant l'outil bond graph. Le travail consistait à développer et automatiser des procédures de génération de modèles et d'indicateurs de défaillances sous forme formelle et interchangeable permettant de les intégrer dans un système global de supervision. Les résultats obtenus ont été appliqués sur deux démonstrateurs : le générateur de vapeur du LAGIS et le pilote de FCC (Fluid Catalytic Cracking) de l'Institut Français du Pétrole à Solaize (Lyon).

Dans les approches de surveillance basées sur des modèles quantitatifs, les performances des procédures de détection et de localisation de défaillances dépendent fortement du modèle utilisé. L'obtention du modèle est une tâche complexe et difficile, plus particulièrement pour des systèmes multi-physiques, tels que ceux du génie des procédés en raison de leur diversité et du couplage des énergies qui les caractérisent. Les premiers travaux relatifs à la surveillance des systèmes multi-physiques par des modèles quantitatifs générés en utilisant l'outil bond graph reposent essentiellement sur l'analyse des propriétés causales et structurelles des modèles bond graphs correspondants. Ces modèles, qui sont avant tout des graphes, sont utilisés pour obtenir de manière générique des indicateurs de défaillances (communément appelés Relations de Redondance Analytique : RRA, dont l'évaluation numérique conduit à des résidus). Ces modèles sont également utilisés pour analyser les conditions de « surveillabilité » du système multiphysique en parcourant les chemins causaux des graphes obtenus.

Dans la thèse, nous avons fait appel à l'outil bond graph pour concevoir et réaliser, sous forme d'une boîte à outils, un générateur de modèles dynamiques formels de systèmes multi-physiques (processus thermofluides). Ce générateur de modèles a pour but de faciliter le travail de modélisation et de construction des RRAs et des résidus nécessaires à la surveillance du système. Les modèles générés peuvent ensuite être exploités hors ligne par d'autres boîtes à outils pour leur intégration dans le système global de supervision développé dans le cadre du projet CHEM. Les procédures développées dans la thèse ont été automatisées à l'aide d'un module appelé « ModelBuilder ». Ce dernier est présenté sous forme d'une interface graphique de telle sorte que l'utilisateur puisse aisément construire les modèles dynamiques et fonctionnels de différentes classes de processus thermofluides, de générer les RRAs et vérifier la « surveillabilité » du processus (définir pour l'opérateur les composants pouvant être surveillés en fonction du cahier des charges spécifié).

1. Advanced decision support system for Chemical/Petrochemical manufacturing processes. Project Nr G1RDCT-2001-00466, CHEM Project 2000; <http://www.chem-dss.org>

2 Travaux en qualité d'ATER

Après la thèse, j'ai occupé de septembre 2005 à août 2006 un poste d'ATER (Attaché Temporaire d'Enseignement et de Recherche) à l'Université des Sciences et Technologies de Lille. Durant cette période, j'ai été rattaché au LAGIS où j'ai continué à travailler sur la surveillance, détection et localisation de défaillances, avec comme application principale les systèmes mécatroniques. J'ai particulièrement travaillé sur la modélisation de ces systèmes en utilisant l'outil bond graph, la génération d'indicateurs de défaillances (relations de redondance analytique et résidus) et l'implémentation des méthodes proposées sur un banc de test développé au LAGIS. Il s'agit d'un système mécatronique constitué d'une partie électrique (moteur à courant continu), d'un réducteur avec possibilité d'injecter du jeu mécanique à amplitude variable, et d'une charge mécanique en rotation. Le but de cette application est de détecter et localiser en ligne les défaillances induites par la variation des paramètres physiques du système mécatronique.

3 Publications liées aux travaux de thèse

Revue internationale avec actes et comités de lecture

- [R1] B. Ould Bouamama, K. Medjaher, A.K. Samantaray and M. Staroswiecki. *Supervision of an industrial steam generator. Part I : Bond graph modelling*. Control Eng. Practice, vol. 14, no. 1, Pages 71-83, 2006.
- [R2] K. Medjaher, A.K. Samantaray, B. Ould Bouamama and M. Staroswiecki. *Supervision of an industrial steam generator. Part II : Online implementation*. Control Eng. Practice, vol. 14, no. 1, Pages 71-83, 2006.
- [R3] A.K. Samantaray, K. Medjaher, B. Ould Bouamama, M. Staroswiecki and G. Dauphin-Tanguy. *Diagnostic bond graphs for online fault detection and isolation*. Simulation Modelling Practice and Theory, vol. 14, no. 3, Pages 237-262, 2006.
- [R4] B. Ould Bouamama, K. Medjaher, M. Bayart, A. K. Samantaray and B. Conrard. *Fault detection and isolation of smart actuators using bond graphs and external models*. Control Eng. Practice, vol. 13, no. 2, Pages 159-175, 2005.
- [R5] B. Ould Bouamama, A.K. Samantaray, K. Medjaher, M. Staroswiecki and G. Dauphin-Tanguy. *Model builder using functional and bond graph tools for FDI design*. Control Eng. Practice, vol. 13, no. 7, Pages 875-891, 2005.
- [R6] K. Samantaray, K. Medjaher, B. Ould Bouamama, M. Staroswiecki, G. Dauphin-Tanguy. *Component Based Modelling of Thermo-fluid Systems for Sensor Placement and Fault Detection*. SIMULATION : Transactions of SCS, vol. 80, no. 7-8, Pages 381-398, 2004.
- [R7] R. Merzouki, K. Medjaher, M.A. Djeziri, B. Ould Bouamama. *Backlash fault detection in mechatronic system*. Mechatronics, vol. 17, pp. 299-310, 2007.

Conférences internationales avec actes et comités de lecture

- [C1] K. Medjaher, A.K. Samantaray, and B. Ould Bouamama. *Diagnostic bond graphs for direct residual evaluation*. In International Conference on Bond Graph Modeling and Simulation (ICBGM'05), pages 307-312. Simulation Series, vol. 37, No. 1, ISBN : 1-56555-287-3, 2005.
- [C2] K. Medjaher, R. Merzouki, B. Ould Bouamama. *Model Based Fault Detection of Backlash in Mechatronic Test Bench*. 45th IEEE Conference on Decision and Control (CDC), pp. 6561 - 6566, December, 2006.
- [C3] K. Medjaher, B. Ould Bouamama, A.K. Samantaray et M. Staroswiecki. *Supervision d'un Générateur de Vapeur par l'Approche Bond Graph*. CIFA'04, 22-24 Novembre 2004, Douz, Tunisia.

Distinction liée à la thèse

Prix des meilleurs travaux « Innovation » au 15^{ème} Congrès de Maîtrise des Risques et Sécurité de Fonctionnement organisé par l'Institut pour la Maîtrise des Risques (ImdR) du 9 au 12 octobre 2006 à Lille.

4 Travaux de recherche en qualité de Maître de Conférences

Mes travaux, depuis mon recrutement en qualité de Maître de Conférences en septembre 2006, concernent la thématique de PHM (Prognostics and Health Management), ou pronostic et gestion de l'état de santé de systèmes. Le PHM a pour but d'estimer l'état courant d'un système physique et de prédire sa durée de fonctionnement avant défaillance (communément appelée RUL : Remaining Useful Life) pour permettre une prise de décision efficace. Comme le montre la figure 1, le PHM est un processus composé de sept modules.

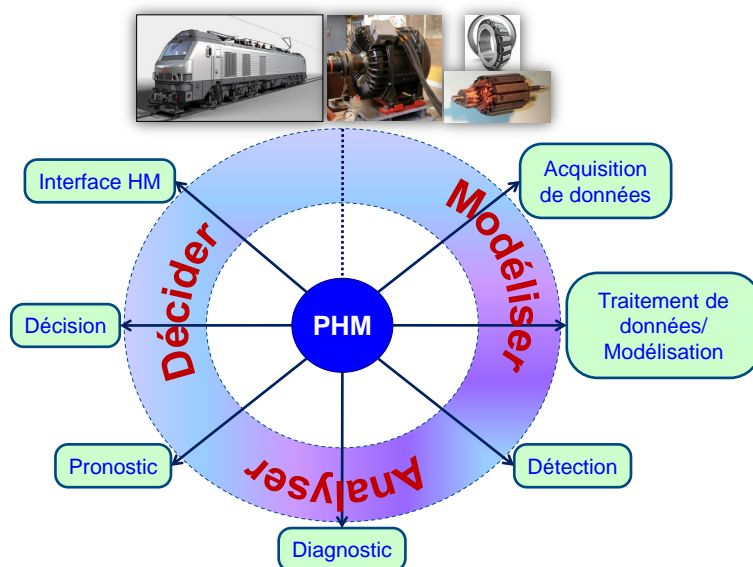


FIGURE 1: Processus générique du PHM.

Différentes méthodes de PHM ont été présentées durant la dernière décennie. Ces méthodes peuvent être classées dans trois approches principales : l'approche guidée par les données, l'approche physique (ou basée sur un modèle de comportement quantitatif) et l'approche hybride qui combine les deux approches précédentes. Dans nos travaux de recherche, nous avons essentiellement travaillé sur l'approche guidée par les données, avec très récemment une orientation vers l'approche hybride de par les avantages qu'elle pourrait offrir. Dans ce qui suit, seuls les travaux réalisés en utilisant l'approche guidée par les données sont présentés. L'orientation vers l'approche hybride sera présentée dans les perspectives de recherche présentées à la fin de ce mémoire.

Nos travaux de recherche s'appliquent sur des composants critiques de systèmes industriels. Pour cela, nous posons comme hypothèse que la défaillance du système global peut être due à la défaillance d'un ou de plusieurs de ses composants critiques. Nous appelons composant critique un composant qui présente un taux de défaillance élevé et/ou dont la défaillance entraîne l'indisponibilité du système dans lequel il est utilisé. Un ou plusieurs composants peuvent exister dans un même système. À titre d'exemples, dans un train on pourrait citer les roulements utilisés pour le guidage de la rotation de l'arbre du moteur électrique, l'induit de ce dernier, le mécanisme d'ouverture et fermeture des portes ou encore des composants du pantographe, notamment l'archet qui sert à capter le courant électrique de la caténaire. La décision de réaliser du PHM sur un composant ou sur plusieurs composants revient à l'exploitant du système. La figure 2 montre les étapes principales permettant d'identifier les composants critiques du système, de traiter les données fournies par les capteurs, d'évaluer l'état de santé du système et de prédire son RUL.

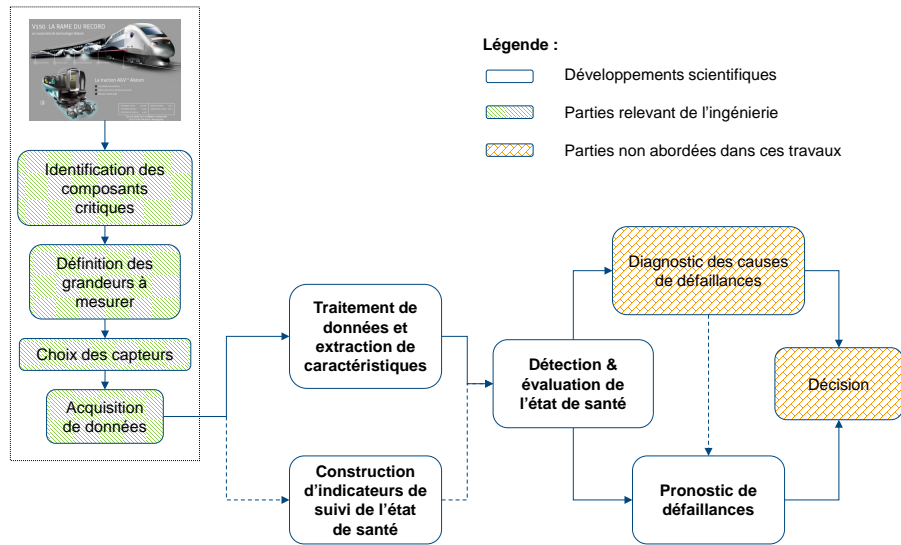


FIGURE 2: Pronostic orienté composants et guidé par les données.

Nos contributions reposent également sur un ensemble d'hypothèses résumées ci-dessous.

1. Une connaissance des composants du système, des interactions entre eux et des phénomènes physiques impliqués existe ou est possible à obtenir (données de retour d'expérience, experts du système, etc.). L'installation des capteurs nécessaires à la surveillance des composants critiques du système est également possible.
2. Les données de surveillance sont tout le temps disponibles. Les capteurs sont supposés fonctionner correctement et sans défaillances tout au long de la durée de vie du système. Dans le cas où un ou plusieurs capteurs tombent en panne, d'autres capteurs redondants sont supposés assurer la continuité des données.
3. Les données acquises sont suffisantes et représentatives des conditions de fonctionnement du composant et de ses états de santé.
4. Seules les défaillances engendrées par des dégradations progressives sont considérées, les défaillances soudaines ne sont pas prises en compte.
5. Les interventions de maintenance ne sont pas considérées pendant le pronostic de défaillances.

Nos contributions peuvent être divisées en quatre parties :

1. Choix des composants critiques et acquisition de données.
2. Traitement des données de surveillance : extraction, sélection et réduction de caractéristiques (ou features) et construction d'indicateurs de santé.
3. Modélisation de dégradations.
4. Évaluation de l'état de santé des composants (health assessment) et prédiction du RUL.

Ces travaux ont été appliqués sur différents systèmes physiques : machines tournantes, transport ferroviaire, machines à outils et systèmes micro-électromécaniques (MEMS).

4.1 Choix des composants critiques et acquisition de données

Les travaux réalisés dans cette partie relèvent de l'ingénierie. Ils traitent des problématiques du choix des composants critiques du système et de l'acquisition de données de surveillance fiables et exploitables par des algorithmes de PHM.

Le choix des composants critiques, qui constitue la première étape de notre approche, se fait sur la base des résultats de différentes analyses (fonctionnelle, dysfonctionnelle, retour d'expérience, etc.). Cette étape est menée conjointement avec l'exploitant et/ou le fabricant du système dont l'expertise est précieuse. Pour la réaliser, nous avons proposé une démarche qui repose sur un ensemble d'outils existants et répandus dans la communauté de la Sécurité de Fonctionnement (SdF) et de la maîtrise des risques. Cette démarche a été initialement mise en place dans le cadre de la thèse CIFRE² de D. A. Tobon-Mejia, thèse réalisée en collaboration avec l'entreprise ALSTOM Transport sur la nouvelle génération de moteurs AGV (Automotrices à Grande Vitesse). Elle a ensuite été affinée tout au long de nos travaux de recherche et de nos collaborations avec ALSTOM Transport sur d'autres types de systèmes telles que les portes de trains, mais également avec d'autres entreprises notamment TORNOS, une entreprise suisse concevant et fabriquant des machines d'usinage à commande numérique de haute précision.

La deuxième étape concerne la définition des grandeurs physiques à surveiller et le choix des capteurs à installer pour surveiller et suivre l'évolution des phénomènes de dégradation des composants.

Enfin, la troisième étape est consacrée à l'acquisition et au pré-traitement des données issues des capteurs. L'objectif est de vérifier les données pour s'assurer de l'absence d'erreurs et, dans le cas contraire, les corriger, les formater pour qu'elles soient faciles à traiter par des logiciels dédiés et éventuellement les ré-échantillonner et/ou les filtrer pour enlever le bruit qui pourrait s'ajouter lors de la phase d'acquisition.

Ces travaux ont fait l'objet de deux articles publiés dans deux conférences internationales avec comité de lecture ([C8], [C15]).

4.2 Extraction de caractéristiques et construction d'indicateurs de santé

Le traitement des données de surveillance constitue la problématique principale de cette partie. Pour la résoudre, nous avons travaillé sur quatre tâches : l'extraction, la sélection et la réduction de caractéristiques et la construction d'indicateurs de santé (Health Indicators).

L'extraction de caractéristiques dépend de la nature des données (ou signaux) à traiter (stationnaires ou non stationnaires) et du domaine de leur utilisation (détection, diagnostic ou pronostic). Les caractéristiques extraites peuvent être classées selon trois catégories : temporelles (paramètres statistiques : moyenne, kurtosis, facteur de crête, etc.), fréquentielles (analyse spectrale, analyse en enveloppe, etc.) et temps-fréquence (décomposition modale empirique, transformée de Hilbert-Huang, etc.).

Les caractéristiques extraites peuvent être plus au moins pertinentes pour caractériser l'évolution de l'état de santé des composants critiques du système. La sélection de caractéristiques a pour but de définir des critères de sélection, telle que la monotonie des caractéristiques, pour ne garder que les plus pertinentes qui peuvent ensuite être utilisées pour la prédiction de l'évolution de la dégradation.

Dans la pratique, il peut arriver que les caractéristiques sélectionnées ne puissent pas être directement exploitées pour estimer l'état actuel et futur du système, à cause notamment de contraintes imposées par les outils de modélisation (comme par exemple le nombre et le type de données

2. Conventions Industrielles de Formation par la REcherche

d'entrées). Dans ce cas, il est nécessaire de réduire le nombre de caractéristiques, sans perdre l'information pertinente, pour permettre leur représentation dans un espace de dimension réduite et faciliter leur interprétation, mais aussi pour gagner en temps d'apprentissage et d'inférence. Dans ce sens, nous avons fait appel à deux techniques. Il s'agit de l'analyse en composantes principales, et de ses variantes non linéaires, et de l'Isomap (Isometric feature mapping). Enfin, dans certains cas d'application, il est possible de fusionner des signaux bruts ou des caractéristiques pour construire ce que nous appelons indicateurs de santé. Chaque indicateur pourra ensuite être utilisé pour représenter l'évolution de l'état de santé du composant critique, estimer son état actuel et prédire son état futur.

Les travaux de recherche développés dans cette partie ont fait l'objet de quatre publications dans des revues internationales avec actes et comités de lecture ([R13], [R15], [R16], [R18]) et de trois conférences internationales avec actes et comités de lecture ([C6], [C7], [C10]).

4.3 Modélisation de dégradations

La modélisation de la dégradation du composant critique joue un rôle central dans le processus du PHM et constitue la problématique principale de cette partie de recherche. Elle a pour but de transformer les caractéristiques et les indicateurs de santé générés dans l'étape précédente en modèles représentant l'initiation et la progression de la dégradation du composant.

La modélisation de la dégradation doit être la plus fidèle possible de ce qui se passe dans le composant. Elle est nécessaire et importante pour estimer à tout instant l'état de santé du composant, détecter les signes précurseurs de l'initiation d'une dégradation et prédire son état futur utile au calcul du RUL. Elle est réalisée dans une phase d'apprentissage hors ligne sur des données traitées (caractéristiques et/ou indicateurs de santé). Les modèles à construire doivent tenir compte de la nature des défaillances (soudaines, dégradations progressives, etc.), du type de données d'entrée (quantitatives ou qualitatives, monodimensionnelles ou multidimensionnelles, stationnaires ou non stationnaires, complètes ou tronquées, etc.) et des conditions de fonctionnement du composant (conditions constantes ou variables). Ils doivent également représenter les incertitudes des caractéristiques et des indicateurs de santé utilisés. En effet, dans la pratique, plusieurs composants d'une même référence testés individuellement dans les mêmes conditions de fonctionnement conduisent rarement aux mêmes valeurs de caractéristiques et d'indicateurs de santé.

Les points évoqués précédemment constituent une sorte de cahier des charges qui conditionne le choix des outils de modélisation. Pour en tenir compte, nous avons fait appel à deux catégories d'outils de modélisation. La première catégorie concerne les outils probabilistes/stochastiques notamment les réseaux bayésiens dynamiques. La seconde catégorie concerne les régressions non linéaires issues de méthodes par apprentissage automatique, notamment les machines à vecteurs de support pour la régression (Support Vector Regression : SVR) et le processus de Gauss pour la régression (Gaussian Process Regression : GPR).

Les réseaux Bayésiens dynamiques permettent de regrouper les états de santé (ou modes de fonctionnement) du composant critique en utilisant, comme entrées, des matrices de caractéristiques extraites des signaux bruts fournis par les capteurs. Ils permettent également de prendre en compte la variabilité et l'incertitude des données lors des phases d'apprentissage et d'inférence. La durée de vie du composant peut ainsi être segmentée en plusieurs états (ou modes) pouvant aller de l'état neuf à l'état défaillant en passant par différents états intermédiaires correspondant à l'évolution de la dégradation. Les différents états du composant et les transitions entre eux sont alors représentés par un vecteur d'états et une matrice de transition du réseau bayésien dynamique correspondant.

Les SVRs, une variante des séparateurs à vaste marge (Support Vector Machines), et le GPR

sont utilisés dans nos travaux pour modéliser l'évolution dans le temps ainsi que les variations des indicateurs de santé extraits des historiques de dégradation. Les modèles obtenus seront ensuite utilisés pour estimer l'état courant du composant, prédire son état futur et calculer son RUL.

Les résultats de ces travaux ont fait l'objet de six publications dans des revues internationales avec actes et comités de lecture ([R12], [R16], [R17], [R19], [R20], [R21]) et de six conférences internationales avec actes et comités de lecture ([C9], [C11], [C12], [C13], [C14], [C17]).

4.4 Évaluation de l'état de santé et prédiction du RUL

Les modèles obtenus dans l'étape de modélisation de la dégradation sont utilisés dans cette partie pour suivre l'état de santé du composant, détecter le plus tôt possible sa dégradation et pronostiquer les éventuelles défaillances pouvant survenir au cours de son utilisation. Nous nous sommes alors intéressés à deux problématiques : l'évaluation de l'état de santé courant du composant et la prédiction de son RUL, et l'évaluation de la performance du pronostic réalisé. L'évaluation de l'état de santé courant du composant critique s'obtient, dans le cas des réseaux Bayésiens dynamiques, par le calcul des probabilités sur les états du modèle. Ce calcul est réalisé par des algorithmes adaptés tel que celui proposé par Viterbi. L'estimation du RUL du composant critique est ensuite obtenue en calculant le temps qui sépare l'état courant du composant de l'état correspondant à sa défaillance. A noter que les durées de séjour dans chacun des états de santé du composant sont supposées être calculées lors de la phase d'apprentissage du modèle du composant et de sa dégradation. Chaque durée de séjour peut être une moyenne calculée sur plusieurs tests pour avoir des durées représentatives d'une population de composants de même référence. Dans le cas des méthodes SVR et GPR, l'état courant est obtenu en estimant la valeur actuelle de l'indicateur de santé. La valeur du RUL est quant à elle obtenue en calculant continuellement le temps entre l'instant courant et l'instant où la valeur de l'indicateur coïncide avec le seuil de défaillance. Une problématique sous-jacente au calcul du RUL, et à laquelle nous nous sommes intéressés, concerne la définition de la valeur du seuil de défaillance. Une juste définition de cette valeur est importante car si le seuil est mal défini, il conduirait à un pronostic inopportun et à une décision de maintenance inadéquate. En effet, trois cas de figure peuvent être envisagés. Le premier cas est celui où la valeur du seuil correspond à l'instant réel de la défaillance, dans ce cas le pronostic est exact. Le deuxième cas est celui où le seuil est défini de façon optimiste, c'est-à-dire que l'instant prédit pour la défaillance est au delà de l'instant réel. Dans ce cas, la prédiction est inappropriée et les conséquences peuvent être catastrophiques (risques d'explosion, de déraillement, d'écrasement, etc.). Enfin, le troisième cas, correspond à celui où le RUL prédit est avant l'instant réel de la défaillance. Dans ce cas, en veillant à ce que l'erreur soit la plus petite possible, on obtient un RUL exploitable pour l'aide à la décision. Dans nos travaux, nous avons particulièrement travaillé sur le troisième cas.

L'évaluation des performances du pronostic réalisé se fait au moyen de différentes métriques. Nous avons notamment travaillé sur l'horizon de pronostic (étendue temporelle des prédictions), la précision et l'exactitude des RULs obtenus et l'opportunité des prédictions (vérifier si les RULs prédits sont exacts, optimistes, ou au contraire pessimistes, c'est-à-dire avant l'instant d'apparition de la défaillance).

Les résultats de cette partie ont fait l'objet de cinq publications dans des revues internationales avec actes et comités de lecture ([R16], [R17], [R19], [R20], [R21]).

4.5 Applications

Les méthodes et algorithmes développés dans le cadre de nos travaux de recherche ont été appliqués sur différents systèmes.

- **Transport ferroviaire** : il s’agit principalement de moteurs AGV (Automotrice à Grande Vitesse) et de portes de tramways. Ces applications ont été réalisées dans le cadre de deux projets de recherche partenariale avec l’entreprise ALSTOM Transport. Le premier projet concerne la fiabilité accrue des machines tournantes embarquées en partenariat avec ALSTOM (Ornans). Le second projet concerne la surveillance et la prédiction du RUL des portes de tramways en partenariat avec ALSTOM (Saint-Ouen).
- **Systèmes d’usinage de précision** : il s’agit de deux applications. La première concerne la surveillance, la détection, le diagnostic et le pronostic de défaillances dans un système multibroches des machines d’usinage de précision de l’entreprise suisse TORNOS. La seconde concerne la prédiction de la durée de vie des outils de coupe utilisés par des machines d’usinage afin de permettre à l’opérateur d’anticiper l’usure de l’outil.
- **Génération d’énergie** : cette application concerne des données fournies par le « Prognostic Center of Excellence » de la NASA sur des cycles de charge et décharge d’un ensemble de batteries Li-Ion. L’objectif a été d’utiliser un sous-ensemble de ces données pour apprendre des modèles et l’autre sous-ensemble restant pour estimer l’état courant des batteries tests et prédire leurs RULs.
- **Machines tournantes** : cette application concerne le pronostic de défaillances de roulements utilisés dans des machines tournantes. Nous avons particulièrement travaillé sur les données de la plateforme Pronostia pour tester et valider nos algorithmes. Cette plateforme, destinée à la réalisation de campagnes de vieillissements accélérés de roulements à billes, a été conçue et réalisée au sein de notre équipe de recherche.
- **Microsystèmes** : cette application concerne la surveillance, la détection et le pronostic de défaillances de microsystèmes électromécaniques (ou MEMS : Micro-ElectroMechanical Systems), notamment de pinces électrostatiques et d’accéléromètres.

4.6 Publications postdoctorales

Revue internationale avec actes et comités de lecture

- [R8] A. Soualhi, K. Medjaher, N. Zerhouni. *Bearing Health monitoring based on Hilbert-Huang Transform, Support Vector Machine and Regression*. IEEE Transactions on Instrumentation and Measurement, article published online 01 July 2014, DOI : 10.1109/TIM.2014.2330494.
- [R9] A. Mosallam, K. Medjaher, N. Zerhouni. *Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction*. Journal of Intelligent Manufacturing, article published online 13 June 2014, DOI : 10.1007/s10845-014-0933-4.
- [R10] K. Medjaher, H. Skima, N. Zerhouni. *Condition Assessment and Fault Prognostics of Microelectromechanical Systems*. Microelectronics Reliability, volume 54, issue 1, pages : 143-151, 2014, DOI : 10.1016/j.microrel.2013.09.013.
- [R11] K. Medjaher, N. Zerhouni. *Framework for a hybrid prognostics*. Chemical Engineering Transactions, volume 33, pages : 91-96, 2013.
- [R12] A. Mosallam, K. Medjaher, N. Zerhouni. *Bayesian approach for remaining useful life prediction*. Chemical Engineering Transactions, volume 33, pages : 139-144, 2013.
- [R13] A. Mosallam, K. Medjaher, N. Zerhouni. *Nonparametric time series modelling for industrial prognostics and health management*. The International Journal of Advanced Manufacturing Technology, volume 6, pages : 1685-1699, 2013, DOI 10.1007/s00170-013-5065-z.
- [R14] K. Medjaher, N. Zerhouni. *Hybrid prognostic method applied to mechatronic systems*. The International Journal of Advanced Manufacturing Technology, volume 69, pages : 823-834, 2013, DOI 10.1007/s00170-013-5064-0.

TABLE 1: Synthèse des publications postdoctorales.

Catégorie	Nombre	Titre
Revue à comités de lecture	14	Trans. on Reliability (IEEE), Trans. on Instrumentation and Measurement (IEEE), Engineering Applications of Artificial Intelligence (Elsevier), Mechanical Systems and Signal Processing (Elsevier), Microelectronics reliability (Elsevier), Journal of Intelligent Manufacturing (Springer), Int. J. of Adv. Manufacturing Technology (Springer), Quality and Reliability Engineering (Wiley) J. of Manufacturing Tech. Management (Emerald), Chemical Engineering Transactions (AIDIC)
Chapitres d'ouvrages	2	Maintenance Modelling and Applications
Conférences internationales à comités de lecture	19	PHM (IEEE), Aerospace Conf. (IEEE), CASE (IEEE), PHM (PHM society), SAFEPROCESS (IFAC), IFAC WC, DCDS (IFAC), INCOM (IFAC), AMEST (IFAC), ECC (EUCA, IEEE, IFAC, CSS)
Conférences nationales à comités de lecture	1	4 ^{èmes} Journées Francophones sur les Réseaux Bayésiens
Vulgarisation scientifique	1	Techniques de l'ingénieur
Présentations dans des groupes de travail de GdRs	3	GT S3 (Sûreté, Surveillance, Supervision) du GdR MACS
Séminaires scientifiques donnés à l'étranger	7	IVHM (UK), IMS (USA), PCoE de la NASA (USA), Univ. Texas (USA), City Univ. Hong Kong (Chine), SIM-Tech (Singapour), USTO (Algérie)

- [R15] A. Mosallam, K. Medjaher, N. Zerhouni. *Time Series Trending for Condition Assessment and Prognostics*. Journal of Manufacturing Technology Management, Vol. 25, Issue : 4, pages : 550-567, 2014
- [R16] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak. *Remaining useful life estimation based on nonlinear feature reduction and support vector regression*. Engineering Applications of Artificial Intelligence, vol. 26, no. 7, pp. 1751-1760, 2013.
- [R17] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak. *Health assessment and life prediction of cutting tools based on support vector regression*. Journal of Intelligent Manufacturing, article published online 19 April 2013, DOI 10.1007/s10845-013-0774-6.
- [R18] F. Camci, K. Medjaher, N. Zerhouni, P. Nectoux. *Feature Evaluation for Effective Bearing Prognostics*. Quality and Reliability Engineering International, vol. 29, pp. 477-486, 2013.
- [R19] K. Medjaher, D.A. Tobon-Mejia, N. Zerhouni. *Remaining useful life estimation of critical components with application to bearings*. IEEE Transactions on Reliability, vol. 61, no. 2, pp. 292-302, 2012
- [R20] D.A. Tobon-Mejia and K. Medjaher and N. Zerhouni. *CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks*. Mechanical Systems and Signal Processing, vol. 28, pages : 167 - 182, DOI : 10.1016/j.ymssp.2011.10.018, ISSN : 0888-3270, 2012
- [R21] Diego A. Tobon-Mejia, Kamal Medjaher, Noureddine Zerhouni and Gerard Tripot. *A Data-Driven Failure Prognostic Method based on Mixture of Gaussians Hidden Markov Models*. IEEE Transactions on Reliability, vol. 61, no. 2, pp. 491-503, 2012

Chapitres d'ouvrages

- [O1] K. Medjaher. Chapter 6 : Fault Diagnostics. *Part : A bond graph model-based fault detection and isolation*. In Maintenance Modelling and Applications. Pages 503-512, 2011, ISBN : 978-82-515-0316-7

- [O2] R. Gouriveau, K. Medjaher. *Chapter 2 : Prognostics. Part : Industrial Prognostic - An Overview*. In Maintenance Modelling and Applications. Pages 10-30, 2011, ISBN : 978-82-515-0316-7

Conférences internationales avec actes et comités de lecture

- [C4] H. Skima, K. Medjaher, N. Zerhouni. *Accelerated life tests for prognostic and health management of MEMS devices*. Second European Conference of the Prognostics and Health Management Society, PHM Society'2014, 8-10 juillet 2014, Nantes, France.
- [C5] A. Mosallam, K. Medjaher, N. Zerhouni. *Integrated Bayesian Framework for Remaining Useful Life Prediction*. IEEE International Conference on Prognostics and Health Management, PHM'2014, 22-25 juin 2014, Spokane (WA), États-Unis.
- [C6] K. Medjaher, N. Zerhouni, J. Baklouti. *Data-Driven Prognostics Based on Health Indicator Construction : Application to PRONOSTIA's Data*. European Control Conference (ECC 2013), 17-19 July 2013, Zurich, Switzerland.
- [C7] A. Mosallam, K. Medjaher, N. Zerhouni. *Unsupervised Trend Extraction for Prognostics and Condition Assessment*. 2nd IFAC Workshop on Advanced Maintenance Engineering, Services and Technology (AMEST'12), 22 - 23 November 2012, Seville, Spain
- [C8] P. Nectoux, R. Gouriveau, K. Medjaher, E. Ramasso, B. Morello, N. Zerhouni, C. Varnier. *PRONOSTIA : An Experimental Platform for Bearings Accelerated Degradation Tests*. IEEE International Conference on Prognostics and Health Management, PHM'12, Denver, USA, 2012
- [C9] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak. *Fault prognostic of bearings by using support vector data description*. IEEE Conference on Prognostics and Health Management, PHM'12, Denver, USA, 2012
- [C10] K. Medjaher, F. Camci, N. Zerhouni. *Feature Extraction and Evaluation for Health Assessment and Failure Prognostics*. First European Conference of the Prognostics and Health Management Society, July 3-5, Dresden, 2012
- [C11] D. Tobon-Mejia, K. Medjaher, N. Zerhouni, G. Tripot. *Estimation of the remaining useful life by using Wavelet Packet Decomposition and HMMs*. In IEEE Aerospace Conference AIAA - 2011, Montana, USA. Pages 1-10, ISBN : 978-1-4244-7350-2, DOI : 10.1109/AERO.2011.5747561, 2011
- [C12] D. Tobon-Mejia, K. Medjaher, N. Zerhouni, G. Tripot. *Hidden Markov models for failure diagnostic and prognostic*. In Prognostics and System Health Management Conference PHM'11, Shenzhen, China. Pages 1 - 8, DOI : 10.1109/PHM.2011.5939488, ISBN : 978-1-4244-7951-1, 2011
- [C13] D. Tobon-Mejia, K. Medjaher, N. Zerhouni. *CNC machine tool health assessment using Dynamic Bayesian Networks*. In 18th World Congress of the International Federation of Automatic Control, IFAC'11. Milano, Italy, 2011
- [C14] D. Tobon-Mejia, K. Medjaher, N. Zerhouni, G. Tripot. *A mixture of gaussians hidden markov model for failure diagnostic and prognostic*. In 6th Annual IEEE Conference on Automation Science and Engineering, CASE'10, Toronto, Canada. Pages 338 - 343, ISBN : 978-1-4244-5447-1, DOI : 10.1109/COASE.2010.5584759, 2010
- [C15] D. Tobon-Mejia, K. Medjaher, N. Zerhouni. *The ISO 13381-1 Standard's failure prognostics process through an example*. In IEEE Prognostics and System Health Management Conference, PHM'2010. Macau, China. Pages 1 - 12, ISBN : 978-1-4244-4756-5, DOI : 10.1109/PHM.2010.5413482, 2010
- [C16] K. Medjaher, N. Zerhouni. *Residual-based failure prognostic in dynamic systems*. In 7th IFAC International Symposium on Fault Detection, Supervision and Safety of Technical Processes, SAFE PROCESS'09, Barcelona, Spain, DOI : 10.3182/20090630-4-ES-2003.00119, 2009
- [C17] K. Medjaher, J.-Y. Moya, N. Zerhouni. *Failure prognostic by using dynamic Bayesian Networks*. In 2nd IFAC Workshop on Dependable Control of Discrete Systems, DCDS'09, Bari, Italy, DOI : 10.3182/20090610-3-IT-4004.00049, 2009
- [C18] K. Medjaher, R. Gouriveau, N. Zerhouni. *A procedure for failure prognostic in dynamic system*. In 13th IFAC Symposium on Information Control Problems in Manufacturing INCOM'09, Moscow, Russia, 2009
- [C19] A. Mechraoui, K. Medjaher, N. Zerhouni. *Bayesian based fault diagnosis : application to an electrical motor*. In 17th IFAC World Congress, Seoul, Korea, DOI : 10.3182/20080706-5-KR-1001.01248, 2008

Vulgarisation scientifique

- [V1] R. Gouriveau, K. Medjaher, E. Ramasso, N. Zerhouni. *PHM - Prognostics and health management. De la surveillance au pronostic de défaillances de systèmes complexes*. Techniques de l'Ingénieur, Mai 2013

5 Insertion dans l'équipe de recherche

Mon arrivée dans l'équipe de recherche actuelle intervient un an après le lancement par le Professeur Nouredine Zerhouni de la thématique PHM. J'y ai contribué à l'émergence de la thématique, à son développement et à sa consolidation. Je suis également impliqué dans la vie scientifique de l'équipe à travers des présentations, la proposition de sujets de stages, l'encadrement de projets de fin d'études, de masters recherche, de doctorants et de post-doctorants, le montage et la gestion de projets de recherche en y intégrant des collègues de l'équipe, la participation aux projets proposés par mes collègues de l'équipe et l'initiation et résolution de nouvelles problématiques de recherche. J'ai également contribué à l'émergence de nouvelles plateformes expérimentales pour tester et valider les méthodes et algorithmes de PHM que nous développons au sein de l'équipe. Enfin, je suis impliqué dans la diffusion à l'échelle nationale et internationale des données expérimentales issues de la plateforme Pronostia, conçue et réalisée au sein de notre équipe de recherche, en organisant le « IEEE PHM 2012 Data Challenge » lors de la « 2012 IEEE Conference on Prognostics and Health Management » qui a eu lieu à Denver aux États Unis.

Les résultats de nos travaux de recherche font régulièrement l'objet de publications dans des revues et conférences internationales reconnues dans le domaine du PHM, ce qui contribue au rayonnement de l'équipe, du département AS2M et de l'institut FEMTO-ST aux niveaux national et international. Nous accordons aussi une importance particulière à la présentation de nos travaux lors de réunions du groupe de travail S3 (Sûreté, Surveillance, Supervision) du GdR MACS pour positionner les travaux de l'équipe au sein de la communauté scientifique nationale. Depuis mon recrutement, j'ai également réalisé des visites et séjourné dans des laboratoires de recherche étrangers afin de confronter nos travaux à ceux des laboratoires d'accueil. J'ai aussi été à l'initiative d'invitations de chercheurs étrangers qui sont venus séjourner dans notre équipe. Cela nous a permis de nouer des collaborations et de capitaliser nos échanges par des publications et des montages de projets.

Enfin, j'ai participé à d'autres types d'activités résumées dans les sous-sections suivantes et qui ont contribué au rayonnement de l'équipe de recherche PHM.

5.1 Encadrement de travaux de recherche

Depuis mon recrutement en qualité de Maître de Conférences, je suis impliqué dans l'encadrement d'un post-doctorant, quatre thèses, quatre Masters 2 Recherche et deux stages de Projets de Fin d'Études (PFE). Parmi les quatre thèses, la première a été soutenue en décembre 2011 et le docteur a été recruté à la fin de sa thèse par l'entreprise AREVA. La deuxième a débuté en décembre 2011, sa soutenance est prévue le 18 décembre 2014 et le doctorant est embauché par l'entreprise Schlumberger. La troisième a débuté en décembre 2012 et la quatrième en octobre 2013, toutes les deux sont en cours.

Je suis par ailleurs titulaire d'une Prime d'Excellence Scientifique (PES) de catégorie « A » depuis le 1^{er} octobre 2012.

5.1.1 Encadrement de post-doctorants

[Postdoc1] **Post doctorat de A. Soualhi**

- Titre : Détection, diagnostic et pronostic de défaillances des machines d'usinage de précision
- Encadrement : K. Medjaher (100 %).

5.1.2 Encadrement de thèses

[Th1] Thèse de D. A. Tobon-Mejia

- Titre de la thèse : Contribution au pronostic industriel de défaillances guidé par les données : approche Bayésienne appliquée aux composants des moteurs électriques.
- Encadrement : N. Zerhouni (30 %) et K. Medjaher (70 %)
- Période : 2008 - 2011
- Date de soutenance : 15 décembre 2011

[Th2] Thèse de A. Fikri Ali Mosallam

- Titre de la thèse : Contribution à la modélisation des processus de dégradation : Application au pronostic de défaillances.
- Encadrement : N. Zerhouni (30 %) et K. Medjaher (70 %)
- Période : 2011 - 2014
- Soutenance prévue le 18 décembre 2014

[Th3] Thèse de W. Elghazel

- Titre de la thèse : Pronostic industriel basé sur des algorithmes distribués des systèmes de capteurs pour la maintenance prédictive.
- Encadrement : N. Zerhouni (20 %), J. Bahi (20 %), K. Medjaher (30 %) et M. Hakem (30 %)
- Période : 2012 - 2015

[Th4] Thèse de H. Skima

- Titre de la thèse : PHM de MEMS distribués.
- Encadrement : C. Varnier (30 %), J. Bourgeois (10 %), K. Medjaher (30 %) et E. Dedu (30 %).
- Période : 2013 - 2016

5.1.3 Masters 2 Recherche et Projets de Fin d'Études

[MR1] Master 2 recherche de A. Mechraoui

- Titre : Diagnostic de défaillances par réseaux Bayésiens.
- Période : février 2007 - juillet 2007
- Encadrement : K. Medjaher (100 %).

[MR2] Master 2 recherche de J-Y Moya

- Titre : Pronostic de défaillances par réseaux Bayésiens dynamiques : application à la plateforme de transfert de palettes SORMEL.
- Période : juillet 2008 - octobre 2008
- Encadrement : K. Medjaher (100 %).

[MR3] Master 2 recherche de C. Xu

- Titre : Estimation des Paramètres d'un Réseau Bayésien Dynamique : Application au Pronostic de Défaillances.
- Période : janvier 2010 - juin 2010
- Encadrement : K. Medjaher (100 %).

[MR4] Master 2 recherche de M.D. Mbodj

- Titre : Caractérisation des phénomènes de dégradation des MEMS pour la prédiction du RUL.
- Période : Juillet 2013 - octobre 2013
- Encadrement : K. Medjaher (100 %).

[PFE1] Projet de Fin d'Études de J. Baklouti

- Titre : Traitement des données de surveillance pour la caractérisation de l'état de santé de composants critiques.
- Période : mars 2012 - septembre 2012
- Encadrement : K. Medjaher (100 %).

[PFE2] Projet de Fin d'Études de H. Skima

- Titre : Surveillance et pronostic de défaillances des MEMS.
- Période : février 2013 - juillet 2013
- Encadrement : K. Medjaher (100 %).

5.2 Évaluation de travaux de recherche

5.2.1 Jurys de thèses

Membre du jury de thèse de Mr. Nizar Chatti (04 décembre 2013)

- Thèse de doctorat de l'Université des Sciences et Technologies de Lille.
- Titre : Contribution à la supervision des systèmes dynamiques à base des Bond Graphs Signés.

Membre du jury de thèse de Mr. Sylvester Aondolumun Aye (26 juin 2014)

- Thèse de doctorat de l'Université de Pretoria, Afrique du Sud.
- Titre : Acoustic emission-based diagnostics and prognostics of slow rotating bearings using Bayesian techniques.

5.2.2 Relecture d'articles de revues

- IEEE Transactions on Automation Science and Engineering (IEEE T-ASE) : 2014, 2011, 2009
- Journal of Intelligent Manufacturing : 2014
- Engineering Applications of Artificial Intelligence : 2013
- Mechanical Systems and Signal Processing : 2013
- IEEE Transactions on reliability : 2014, 2013, 2012
- Mechatronics Journal : 2013
- Mathematical and Computer Modelling of Dynamical Systems : 2013
- Sensors Journal (open access) : 2012
- Information Sciences (Elsevier) : 2009

5.2.3 Relecture de chapitres de livres

- Diagnostics and Prognostics of Engineering Systems : Methods and Techniques (Book), 2011

5.2.4 Relecture d'articles de conférences

- Conference of the Prognostics and Health Management Society : relecteur depuis 2009

- International Conference on Advanced Intelligent Mechatronics (AIM) : 2014
- IFAC World Congress : 2013, 2011
- ICRA : 2013
- IEEE SSD : 2013
- Systol : 2013
- ICSC : 2013
- IEEE PHM, First European PHM conference (PHM Society), PHM China : 2012
- IMAACA : 2012
- IEEE Conference on Automation Science and Engineering (CASE) : 2011
- IEEE Conference on Decision and Control (CDC) : 2011, 2009 et 2008
- IFAC Conference SAFEPROCESS : 2009
- Performances et Nouvelles Technologies en Maintenance (PENTOM) : 2009
- Dependable Control of Discrete Systems (DCDS) : 2009
- Conférence Internationale de Modélisation, Optimisation et Simulation des Systèmes : 2008

5.3 Rayonnement scientifique

5.3.1 Comités d'organisation de conférences

- Membre du comité d'organisation du 9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, SAFEPROCESS'15, qui aura lieu à Paris du 2 au 4 septembre 2015 (<http://safeprocess15.sciencesconf.org/>).
- Membre du comité scientifique international et review manager de la seconde édition de la conférence PHM Europe (<http://www.phmsociety.org/events/conference/phm/europe/14/>).
- Membre du comité de pilotage de la conférence AIM 2014 (<http://www.aim2014.org/>).
- Membre du « Technical Program Committee » de la conférence SSD'14 (11th International Multi-Conference on Systems, Signals and Devices).
- Membre du comité d'organisation de la « 2012 IEEE Conference on Prognostics and System Health Management (PHM) » sponsorisée par IEEE et Reliability Society.
- Chair de la session « PHM for electronics applications » lors de la seconde conférence européenne de PHM qui a eu lieu à Nantes du 8 au 10 juillet 2014.
- Co-chair de la session « PHM in various industrial applications » lors de la Conférence internationale PHM 2013 (<http://www.aidic.it/phm/>).
- Co-chair de la session « Bond Graphs for Supervision System Design » lors de la conférence internationale SAFEPROCESS 2009 (<http://safeprocess09.upc.es/>).

5.3.2 Organisation d'un data challenge en PHM

- Co-organisateur du PHM data challenge 2012 de la 2012 IEEE PHM Conference qui a eu lieu à Denver aux USA (http://www.phmconf.org/phm_data_challenge.htm).
- Participation à la description de la plateforme Pronostia et des données expérimentales de vieillissement accéléré des roulements utilisés.
- Participation à la diffusion des données et à l'évaluation des résultats des challengers.

5.3.3 Invitations, séjours et séminaires scientifiques

- **Invitation** en juin - juillet 2011 de Fatih Camci, chercheur au « IVHM (Integrated Vehicle Health Management) Centre », School of Applied Sciences, Cranfield University, United Kingdom. Deux publications communes, un article dans une revue internationale [R18] et une

conférence internationale [C10], ont été produites suite à cette collaboration.

– **Séjours à l'étranger**

- Février 2009 : séjour d'une semaine au sein de l'institut SimTech à Singapour. Le séjour a été réalisé dans le cadre du projet IM@PRO du programme MERLION.
- Mai 2013 : séjour au centre IVHM de l'Université de Cranfield sur invitation de F. Camci. L'objectif du séjour était de consolider la collaboration déjà initiée lors du séjour en 2011 de F. Camci au département AS2M de l'institut FEMTO-ST. Suite à cela, nous avons envisagé de pérenniser la collaboration à travers divers échanges. Il est ainsi prévu un séjour d'un mois dans le courant de l'automne 2014 au sein du « IVHM » du doctorant A. Mosallam. Ce séjour s'inscrit dans le cadre du programme de mobilité doctorale 2014 soutenu par la région Franche-Comté.

– **Séminaires scientifiques**

- K. Medjaher. Probabilistic Framework for Prognostics and Health Management. Integrated Vehicle Health Management Centre (IVHM), 17th April 2013, Cranfield University, UK.
- K. Medjaher, D.A. Tobon-Mejia, N. Zerhouni, G. Tripot. Data-Driven Prognostics Approach for Remaining Useful Life Estimation : Application to Alstom's trains. 23rd Industry Advisory Board Meeting of IMS, 16 - 18 May, Michigan, USA, 2012.
- K. Medjaher. A Data-Driven Approach for Prognostics and Health Management. Prognostics Center of Excellence, NASA Ames Research Center, CA, USA, 21st May 2012.
- K. Medjaher. Prognostics and Health Management of Industrial Systems : A Data-Driven Approach. Texas University at Austin, Tuesday 22nd May 2012.
- K. Medjaher, R. Gouriveau, N. Zerhouni. Condition-Based Maintenance and Predictive Maintenance. City University of Hong Kong, Mai 2011.
- K. Medjaher. Pronostic et suivi de l'état de santé des équipements industriels. Séminaire organisé à l'Université des Sciences et Technologies d'Oran, December 2011.
- R. Gouriveau, K. Medjaher. Prognostics in Intelligent Maintenance : Fault Diagnostics and Prognostics Using Artificial Intelligence Tools. Simtech, Singapour, February 2009.

5.3.4 Présentations au sein du Groupe de Travail S3 du GdR MACS

- A. Mosallam, K. Medjaher, N. Zerhouni. A Data-driven Approach for Remaining Useful Life Prediction of Critical Components. ENSAM Paris, 28 janvier 2014.
- D. A. Tobon-Mejia, K. Medjaher, N. Zerhouni, G. Tripot. Pronostic industriel de défaillances par l'utilisation des techniques de l'intelligence artificielle. ENSAM Paris, 18 janvier 2012.
- K. Medjaher, D. A. Tobon-Mejia, N. Zerhouni. Pronostic de défaillances guidé par les données : application à l'usure des outils de coupe. ENSAM Paris, 3 novembre 2011.

5.4 Fonctions scientifiques et administratives

- Membre élu du Conseil Scientifique de l'ENSMM depuis mars 2013.
- Correspondant pour FEMTO-ST du Groupe de Travail S3 du GdR MACS (<http://gt-s3.cran.univ-lorraine.fr/>, www.univ-valenciennes.fr/GDR-MACS).
- Membre de la commission de recrutement des Maîtres de Conférences de l'ENSMM (2012).
- Membre du comité de sélection pour le recrutement d'un Maître de Conférences à l'Université de technologie de Troyes (automne 2014).
- Membre du groupe de travail « Évaluation des élèves ingénieurs de l'ENSMM », 2013.

5.5 Responsabilités exercées dans des projets liés à la recherche

Projet MainPreSI (Maintenance Prédictive des Systèmes Industriels)

- Type de projet : Interreg (France - Suisse).
- Durée du projet : 30 mois (janvier 2013 - juin 2015).
- Responsabilité : porteur du projet et chef de file pour la partie française.

Projet région sur la Maintenance conditionnelle et Prédictive des systèmes industriels

- Type de projet : région.
- Durée du projet : 2 ans (septembre 2012 - août 2014).
- Responsabilité : porteur du projet.

Projet PHM sur des portes de trains

- Type de projet : recherche partenariale avec l'entreprise ALSTOM Transport.
- Durée du projet : 18 mois (janvier 2012 - juin 2013).
- Responsabilité : porteur du projet.

Projet région sur le PHM de MEMS distribués

- Type de projet : région.
- Durée du projet : 2 ans (septembre 2013 - août 2015).
- Responsabilité : responsable de la partie « pronostic de défaillances des MEMS ».

Projet IM@PRO (Intelligent Maintenance And PROgnostic)

- Type de projet : programme MERLION entre la France et le Singapour.
- Durée du projet : 2 ans (janvier 2009 - décembre 2010).
- Responsabilité : co-animateur du projet (échanges et séjours scientifiques France - Singapour).

Projet FAME (Fiabilité Accrue des Machines Embarquées)

- Type de projet : Pôle microtechniques, programme AMIMAC (Apport des microtechniques à l'augmentation de performances et de fiabilité des machines électriques embarquées).
- Durée du projet : 3 ans (janvier 2008 - décembre 2010).
- Responsabilité : responsable scientifique des WPs 1 (capteurs, instrumentation quantitative) et 3 (Méthodes d'analyse, monitoring).

Projet SMAC (S-maintenance et cycle de vie)

- Type de projet : Interreg France - Suisse.
- Durée du projet : 3 ans (septembre 2008 - septembre 2011).
- Responsabilité : responsable pour la partie AS2M du sous-projet 4 (réseau de capteurs, supervision, surveillance et diagnostic).

Projet ALTIDE (Aide à La Traçabilité Intelligente des Équipements)

- Type de projet : FUI.
- Durée du projet : 3 ans (septembre 2011 - septembre 2014).
- Responsabilité : implication dans le sous-projet 6 (modèle des données et plateforme e-maintenance) dont notre département est leader.

Activités d'enseignement

Mes activités d'enseignement à l'ENSMM concernent les domaines de l'automatique et de l'informatique industrielle des formations initiale, continue et par apprentissage ainsi que les niveaux première, deuxième et troisième année.

En formation initiale, j'enseigne l'automatique, la mécatronique, la détection, le diagnostic et le pronostic de défaillances de systèmes multi-physiques. En formation par apprentissage, j'ai élaboré le cours, les TDs et les TP du module « Systèmes Automatisés Industriels » et en formation continue j'enseigne l'automatique des systèmes linéaires continus dont je suis responsable.

J'ai aussi contribué à l'élaboration des programmes de deux nouvelles options « mécatronique » et « ingénierie des systèmes de production ». Concernant l'option « mécatronique », j'ai mis en place un nouveau module sur la modélisation et l'analyse des systèmes mécatroniques. Pour l'option « ingénierie des systèmes de production », j'ai introduit le module ingénierie de la maintenance et fait l'acquisition et la mise en place d'une maquette de diagnostic de pannes pour les mini-projets.

En plus des cours dispensés, j'assure le suivi des élèves durant leurs stages et mini-projets réalisés dans le cadre de leur formation. Ces suivis sont listés ci-dessous :

- Stages d'immersion (deuxième année ingénieur).
- Stages de Projets de Fin d'Études (PFE).
- Mini-projets des options « Ingénierie des Systèmes de Production » et « Mécatronique ».
- Mini-projets et projets réalisés dans le cadre de la plateforme partenariale de l'ENSMM.

Le tableau 2 résume les enseignements que j'ai dispensés depuis mon arrivée à l'ENSMM.

Je suis par ailleurs membre du groupe de travail « Évaluation des élèves ingénieurs de l'ENSMM » dont le but est d'identifier les problèmes du processus d'évaluation des élèves et de proposer des solutions pour l'améliorer.

TABLE 2: Résumé des enseignements réalisés depuis septembre 2006 à l'ENSMM

Niveau	Type	Intitulé	Volume/an	Année
Cycle préparatoire ^a	C	Automatique continue	18 h	depuis 2006
1 ^{ère} année	TD	Automatique continue et échantillonnée	24 h	depuis 2006
1 ^{ère} année	TP	Automatique continue et échantillonnée, Grafcet	48 h	depuis 2006
1 ^{ère} année ITII ^b	C	Diagnostic automatique de défaillances	16 h	2006 - 2007
1 ^{ère} année ITII	TD	Diagnostic automatique de défaillances	8 h	2006 - 2007
2 ^{ème} année	TD	Automatique avancée (représentation d'état, commande par retour d'état)	8 h	2006 - 2011
2 ^{ème} année	TP	Automatique avancée (représentation d'état, commande par retour d'état)	12 h	2006 - 2011
2 ^{ème} année	TD	Commande par microcontrôleurs	4 h	depuis 2006
2 ^{ème} année	TP	Commande par microcontrôleurs	40 h	depuis 2006
2 ^{ème} année ITII	C	Systèmes automatisés industriels	8 h	2006 - 2011
2 ^{ème} année ITII	TD	Systèmes automatisés industriels	10 h	2006 - 2011
2 ^{ème} année ITII	TP	Systèmes automatisés industriels	12 h	2006 - 2011
3 ^{ème} année MCT ^c	C	Modélisation et analyse des systèmes mécatroniques	12 h	depuis 2008
3 ^{ème} année MCT	TD	Modélisation et analyse des systèmes mécatroniques	8 h	depuis 2008
3 ^{ème} année ISP ^d	C	Détection, diagnostic et pronostic de défaillances	6 h	depuis 2008
3 ^{ème} année ISP	TD	Détection, diagnostic et pronostic de défaillances	6 h	depuis 2008
3 ^{ème} année ISP	C/TD	Évaluation de performances	6 h	depuis 2008
3 ^{ème} année ISP	TP	Simulation de systèmes de production	12 h	depuis 2008

^a. Formation continue

^b. ITII : Institut des Techniques d'Ingénieur de l'Industrie (formation par apprentissage)

^c. MCT : option mécatronique

^d. ISP : Ingénierie des Systèmes de Production

Deuxième partie

Synthèse des activités de recherche

Introduction générale

1 Contexte/Motivation

Les récents accidents industriels survenus en France (déraillement du train à Brétigny-sur-Orge dans la région parisienne en juillet 2013) et dans le monde (explosion de plateforme pétrolière Deepwater Horizon dans le golfe du Mexique aux États-Unis en avril 2010) montrent qu'il est indispensable de continuellement surveiller les équipements et les infrastructures pour pouvoir détecter les défauts et les dégradations dès leur installation, suivre leur évolution et agir à temps et de façon efficace afin d'éviter des situations indésirables, voire catastrophiques sur les plans humain, environnemental et économique. Pour cela, une mutation des maintenances traditionnelles de type corrective et préventive systématique vers des politiques de maintenances intelligentes notamment la maintenance basée sur l'état (Condition-Based Maintenance : CBM) et la maintenance prédictive est plus que nécessaire. En effet, contrairement aux maintenances traditionnelles pour lesquelles les interventions sont réalisées après l'apparition de la défaillance ou indépendamment de l'état du système, la CBM s'appuie sur l'état courant, estimé ou réel, du système pour décider des interventions. Dans le cas d'une maintenance prédictive, l'état courant est projeté dans le futur pour prévoir les futures actions de maintenance. Ces deux politiques intelligentes permettent ainsi d'augmenter la disponibilité, la fiabilité et la sécurité du système tout en réduisant les coûts d'exploitation en jouant sur ceux de la maintenance.

La mise en œuvre de ces nouvelles maintenances requiert une démarche scientifique impliquant différentes tâches telle que la surveillance, la modélisation, l'analyse et l'aide à la décision. Ces tâches font partie du concept de PHM : Prognostics and Health Management que l'on peut traduire en pronostic et gestion de l'état de santé de systèmes industriels.

La différence entre CBM et PHM n'est pas aisée à établir. En effet, dans la littérature scientifique il n'est pas rare de trouver des auteurs qui confondent les deux concepts. La CBM est un concept de maintenance. Elle a été la première à être développée et utilisée notamment par l'armée américaine au moment où le pronostic n'était pas encore introduit. Elle était alors associée aux tâches de surveillance, de détection et de diagnostic. Ce concept a ensuite évolué vers la CBM+ avec l'intégration de tâches de prédiction de l'état de santé du système. Avec l'introduction et le développement du pronostic, ce dernier a été utilisé pour compléter les tâches de surveillance, de détection et de diagnostic. Ces tâches, ainsi que les données qui y sont issues, sont utilisées pour gérer l'état de santé du système. On parle alors de PHM. Ce dernier comporte les mêmes fonctionnalités que la CBM et CBM+, mais avec le pronostic en plus pour anticiper la défaillance et décider en conséquence. Ainsi, certains auteurs considèrent le PHM comme support permettant la mise en œuvre de la CBM et CBM+. Dans nos travaux de recherche, nous nous intéressons au PHM.

2 État de l'art

Le PHM est une discipline qui traite de l'étude des mécanismes de défaillance de systèmes physiques dans le but de mieux gérer leur état de santé. Il a été introduit vers la fin des années 90 - début des années 2000 par des chercheurs et industriels américains [25,72,85,87,120,155,162]. Il n'a depuis cessé de progresser et de gagner en intérêt au sein des communautés scientifique et industrielle. Un intérêt qui s'explique par le fait que le PHM est une démarche complète et intégrée qui aborde les principales tâches nécessaires à la surveillance, au suivi et à la gestion de l'état de santé de systèmes industriels. Le PHM est un processus composé de sept modules, comme le montre la figure 1.

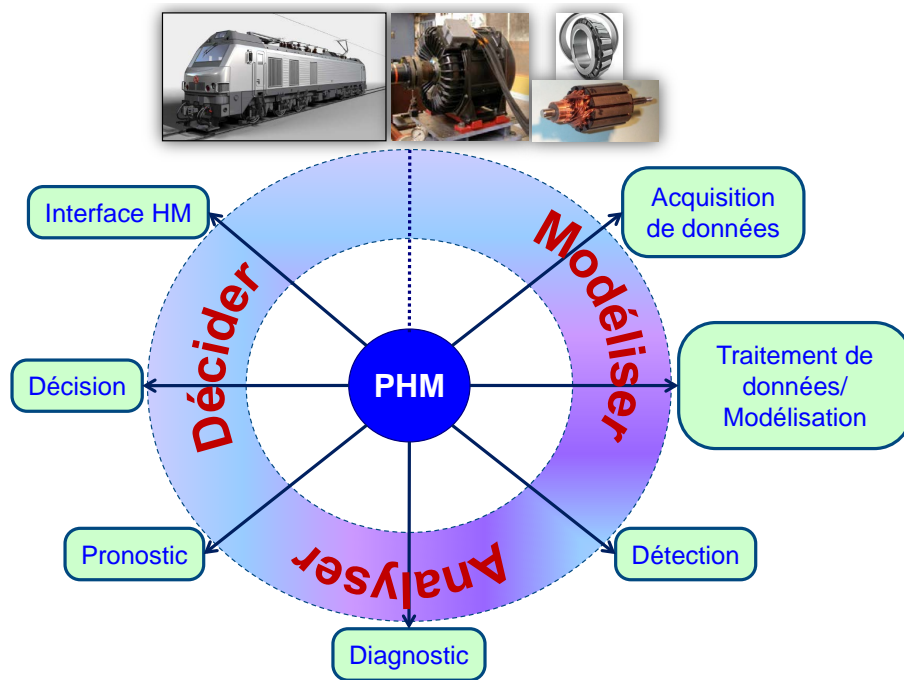


FIGURE 1: Modules du PHM.

- Acquisition de données : ce module a pour but de fournir des données de surveillance permettant de suivre dans le temps l'état de santé du système industriel. Les données peuvent provenir de différents capteurs installés à différents endroits ou des opérateurs travaillant ou maintenant le système. Ces données sont récupérées par l'intermédiaire de cartes d'acquisition ou de fichiers d'enregistrement dédiés et stockées dans une base de données sûre et sécurisée. Elles sont ensuite prétraitées pour s'assurer qu'elles sont complètes, fiables et prêtes au traitement.
- Traitement de données : les données acquises sont ensuite traitées pour extraire des informations pertinentes pouvant renseigner sur le comportement du système, la présence d'anomalies, l'initiation et la propagation de dégradations. Les informations extraites servent aussi à caractériser et modéliser les phénomènes d'intérêt qui se déroulent au sein du système.
- Détection : les sorties des capteurs et les observations des opérateurs sont continuellement comparées aux sorties des modèles des comportements nominaux préalablement construits pour détecter d'éventuelles anomalies sur le système. La détection des anomalies nécessite différents seuils définis en fonction de critères (performance, sécurité, etc.) établis par l'exploitant du système.

- Diagnostic : il correspond à la localisation et l'identification des causes des anomalies ou défaillances constatées sur le système. Il s'appuie sur une connaissance fine des composants du système, des interactions entre les composants, des conditions de fonctionnement et environnementales et du contexte dans lequel évolue le système.
- Pronostic : ce module s'appuie sur les résultats de la détection et éventuellement sur ceux du diagnostic pour prédire la durée de fonctionnement avant défaillance du système. Cette prédiction nécessite de connaître l'état actuel du système et ses futures conditions d'utilisation.
- Aide à la décision : les informations et les connaissances capitalisées à partir des modules précédents sont exploitées par ce module pour définir les actions à mettre en place pour permettre la conduite du système et assurer la continuité de ses fonctions attendues. Les actions recommandées peuvent être de type reconfiguration des lois de commande suite à une anomalie ou défaillance, accommodation de la situation courante, arrêt pour maintenance, arrêt d'urgence, etc.
- Interface Homme - Machine : ce module reçoit les informations de tous les modules précédents et les affiche ou les stocke sous différentes formes pour une utilisation en ligne ou ultérieure.

Même si chacun des modules introduits précédemment a son importance dans la réalisation d'un PHM pertinent, dans nos travaux de recherche nous nous sommes focalisés sur le pronostic de défaillances, avec comme modules supports l'acquisition et le traitement de données. Ce choix est principalement motivé par le fait que la détection et le diagnostic de défaillances, qui sont en amont du pronostic, sont des activités matures et bien développées aussi bien au niveau scientifique qu'au niveau industriel [54–56,89,142,157]. Les modules aide à la décision et interface homme-machine n'ont pas été abordés dans les travaux de recherche présentés dans ce mémoire. Comparé au diagnostic, qui intervient *a posteriori* suite à une défaillance pour rechercher les causes, le pronostic a pour but d'anticiper la défaillance et permet ainsi à l'exploitant de ne pas subir les conséquences des défaillances, d'augmenter la disponibilité de ses systèmes, d'améliorer leur sécurité et de réduire les coûts de maintenance, car les interventions ne sont pas réalisées dans l'urgence. La différence entre le diagnostic et le pronostic est illustrée sur la figure 2.




FIGURE 2: Diagnostic vs pronostic.

Depuis l'introduction du concept de PHM, plusieurs définitions de pronostic de défaillances sont proposées dans la littérature scientifique [4, 25, 56, 72, 85, 87, 103, 120, 155, 162, 175]. Ce nombre important de définitions est dû à l'intérêt croissant accordé par la communauté scientifique à cette thématique de recherche mais aussi au parcours et à la sensibilité applicative des auteurs. Cependant, toutes ces définitions s'accordent sur l'aspect prédictif de l'instant de la défaillance accompli par le pronostic. Dans ce mémoire, et dans un souci d'homogénéité, nous proposons d'utiliser la définition communément admise dans la communauté PHM. Le pronostic y est défini comme étant la prédiction de la durée de fonctionnement avant défaillance (appelé RUL : Remaining Useful Life) d'un système en connaissant son état de santé courant et ses futures conditions d'utilisation.

Le pronostic de défaillances peut être réalisé selon différentes méthodes utilisant différents outils de traitement, de modélisation et d'analyse. Ces méthodes peuvent être regroupées dans différentes catégories ou approches. Des tentatives de classification des approches de pronostic sont proposées dans la littérature scientifique. La première classification a été proposée par Lebold et Thurston en 2001 [72] et a servi de référence pour les classifications qui ont suivi. Elle a une forme pyramidale et distingue trois approches : le pronostic basé sur un modèle, le pronostic guidé par des données et le pronostic basé sur l'expérience. À ces trois approches, les auteurs ont associé quatre critères : la complexité, le coût, la précision et l'applicabilité de chacune d'entre elles. En 2006, Jardine *et al.* [56] ont proposé une autre classification dans laquelle ils considèrent également trois approches mais légèrement différentes de celles proposées par Lebold et Thurston. Il s'agit du pronostic basé sur des outils statistiques, du pronostic utilisant des outils de l'intelligence artificielle et du pronostic avec modèles physiques. En 2009, Heng *et al.* [44] suggèrent quatre approches. Les auteurs gardent les trois approches initialement proposées par Lebold et Thurston auxquelles ils ajoutent une nouvelle approche appelée approche intégrée combinant le pronostic guidé par les données avec le pronostic basé sur l'expérience. En 2010, Peng *et al.* [114] suppriment l'approche basée sur l'expérience et proposent deux autres approches à savoir l'approche basée sur la connaissance et l'approche basée sur la fusion de modèles. À la même année, Zio et Di Maio [175] proposent de ne retenir que deux approches : avec ou sans modèles. Sikorska *et al.* [131] proposent en 2011 quatre approches : la première est basée sur des modèles de durée de vie, la deuxième repose sur des modèles de connaissance, la troisième utilise des réseaux de neurone et la quatrième des modèles physiques. Dans le même esprit, nous avons proposé en 2012 une tentative de synthèse des différentes approches proposées à cette date avec un niveau de granularité plus fin [150]. Enfin, J. Lee *et al.* suggèrent, dans leur récente revue des travaux de PHM sur les machines tournantes, trois approches : l'approche basée sur un modèle physique, l'approche guidée par les données et l'approche hybride [74].

L'étude et l'analyse des différentes classifications proposées dans la littérature, et résumées dans le paragraphe ci-dessus, nous a conduit à constater que les regroupements de méthodes proposés ont été dictés principalement par le type de données et les outils de formalisation utilisés. En outre, en y regardant de plus près, on relève que l'approche basée sur un modèle revient souvent et que les autres approches présentent des similitudes entre elles par les outils qu'elles utilisent. Fort de ce constat, la communauté PHM tend de plus en plus vers une classification unifiée et consensuelle entre les différentes propositions publiées dans la littérature. Elle propose trois approches : le pronostic guidé par les données, le pronostic basé sur un modèle physique et le pronostic hybride (figure 3). Dans ce mémoire nous avons choisi de suivre cette suggestion.

Pronostic basé sur un modèle physique

Les méthodes proposées dans cette approche s'appuient sur l'utilisation de modèles analytiques issus de lois de la physique (mécanique, chimie, électricité, hydraulique, etc.). Ces modèles sont

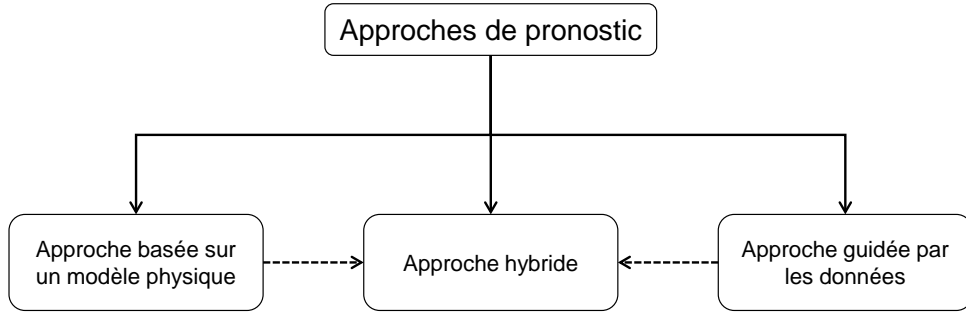


FIGURE 3: Approches de pronostic de défaillances.

exploités pour représenter et suivre au cours du temps le comportement du système et de sa dégradation. Cette dernière est représentée par un ou plusieurs paramètres dont la variation influe sur la dynamique et le comportement global du système. Le principe du pronostic basé sur un modèle est résumé sur la figure 4.




FIGURE 4: Principe du pronostic basé sur un modèle physique.

La majeure partie des méthodes de pronostic à base de modèle publiées dans la littérature traite de fissures, cassure par fatigue, usure et corrosion. Les outils utilisés dans cette approche concernent la modélisation multiphysique (équations algèbro-différentielles linéaires et/ou non linéaires, représentation d'état, etc.), les lois de fatigue et de résistance des matériaux, la modélisation en éléments finis et la notion de résidus [29, 63, 78–81, 85, 86, 122].

Pronostic guidé par les données

Les méthodes développées dans cette approche cherchent à transformer les données de surveillance et d'exploitation en informations pertinentes permettant de renseigner sur l'évolution de la dégradation du système. Elles reposent sur le principe de deux phases, une première phase conduite hors ligne pour comprendre et apprendre le comportement de la dégradation et une seconde phase réalisée en ligne pour estimer l'état de santé courant du système et prédire sa durée de fonctionnement avant défaillance (figure 5).

L'approche guidée par les données fait appel à divers outils de traitement et de modélisation de données. La majeure partie de ces outils est issue du domaine de l'intelligence artificielle. Les plus répandus sont les réseaux de neurone et leurs variantes [32, 51, 57–59, 67, 153, 154, 163, 164, 168], les méthodes statistiques, probabilistes et stochastiques notamment les modèles de Markov cachés [12, 27, 31, 36, 129], les réseaux Bayésiens dynamiques [37, 91, 103, 121, 146, 148, 150] et les processus stochastiques [10, 11, 40, 65, 70, 133], l'analyse de tendance et les régressions [46, 73, 108, 117, 167, 169], les filtres de Kalman [118, 138, 139], le filtre particulaire [26, 112] et l'analyse de

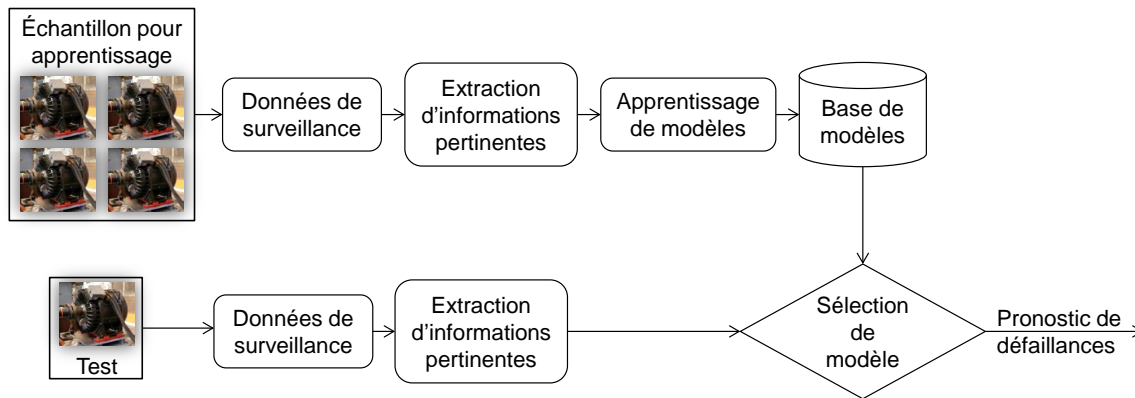


FIGURE 5: Principe du pronostic guidé par les données.

similarités [66, 176].

Pronostic hybride

Cette approche fait appel aux modèles physiques et aux données de surveillance pour estimer l'état courant du système et prédire sa durée de fonctionnement avant défaillance. Elle bénéficie ainsi des avantages des deux approches précédentes, mais aussi de leurs inconvénients. Cependant, son avantage majeure réside dans sa capacité à combiner des outils utilisés dans les approches physiques et guidée par les données en fonction du système étudié, de ses conditions de fonctionnement et de son contexte d'utilisation. C'est une approche pragmatique, applicable aussi bien au niveau composant qu'au niveau système et qui mérite d'être davantage développée. Dans la littérature scientifique, on trouve peu de travaux utilisant l'approche hybride [92, 95]. Cela est dû principalement à la spécialisation des chercheurs qui ont tendance à orienter leurs travaux exclusivement vers une seule approche, basée sur un modèle ou guidée par les données.

3 Positionnement scientifique

Comparée à l'approche guidée par les données, l'approche basée sur un modèle physique est celle qui offre plus de précision. En outre, c'est une approche interprétable car les paramètres des modèles obtenus sont directement ou indirectement (par une combinaison de paramètres) liés aux grandeurs physiques du système. Une dégradation dans le système induit systématiquement une déviation d'un ou de plusieurs paramètres du modèle. Ainsi, en plus de la prédiction de la durée de fonctionnement avant défaillance, il est possible d'identifier les composants responsables de la dégradation et/ou de la défaillance. Cependant, en dépit de la précision du pronostic réalisé, cette approche est difficile à mettre en œuvre sur des systèmes industriels à cause de la complexité et de la pluridisciplinarité des phénomènes physiques qui sont mis en jeu.

L'approche guidée par les données offre un meilleur compromis en termes de précision, de coût de mise en œuvre et d'applicabilité. En effet, cette approche dispense l'utilisateur de la construction de modèles complexes en lui offrant l'alternative de travailler sur des données enregistrées par des capteurs ou des opérateurs. Le développement des capteurs et des systèmes de surveillance combiné aux performances de plus en plus croissantes des calculateurs offrent des capacités de traitement, d'analyse et d'apprentissage remarquables et facilitent ainsi la mise en œuvre de cette approche. Le tableau 3 résume les avantages et les inconvénients de chaque approche.

TABLE 3: Pronostic guidé par les données vs pronostic basé sur un modèle.

Approche guidée par les données	Approche basée sur un modèle
<ul style="list-style-type: none"> – Avantages <ul style="list-style-type: none"> – Simplicité de mise en œuvre. – Faible coût. – Inconvénients <ul style="list-style-type: none"> – Besoin de données expérimentales représentatives des phénomènes de dégradation. – Variabilité des données issues des tests de vieillissement accéléré même pour un même type de composant utilisé avec les mêmes conditions de fonctionnement. – Absence de causalité physique entre les données des tests et l'évolution des dégradations. 	<ul style="list-style-type: none"> – Avantages <ul style="list-style-type: none"> – Approche déterministe et précise. – Réutilisation des modèles obtenus et possibilité de simuler plusieurs dégradations à la fois (dérive des paramètres du modèle). – Inconvénients <ul style="list-style-type: none"> – Difficulté d'obtention des modèles de dégradation. – Coût de mise en œuvre élevé. – Difficile à appliquer sur des systèmes complexes.

La pluridisciplinarité et la complexité des phénomènes physiques caractérisant les systèmes industriels ajoutés au coût relativement élevé des moyens expérimentaux nécessaires à la génération de modèles de dégradation rendent difficile la mise en œuvre de l'approche basée sur un modèle physique. Cela a été conforté par nos différentes collaborations avec des partenaires industriels. À titre d'exemple, il est très difficile d'obtenir un modèle exploitable du comportement nominal incluant les dégradations d'un moteur électrique d'un train à grande vitesse. En effet, le moteur considéré est un système complexe faisant intervenir différents phénomènes physiques (électriques, thermodynamiques, mécaniques, hydrauliques, etc.) et par conséquent, sa modélisation nécessite des compétences pluridisciplinaires. En outre, pour que le modèle généré soit exploitable il faut qu'il soit simple, si possible linéaire, avec des paramètres stationnaires et qu'il tienne compte des conditions de fonctionnement et environnementales variables. Ainsi, la difficulté de construire des modèles facilement exploitables, le coût relativement excessif et la faible applicabilité de l'approche basée sur un modèle nous ont conduit à choisir l'approche guidée par les données. Ce choix a été motivé par la simplicité de mise en œuvre de l'approche sur des systèmes industriels, son faible coût et ses résultats acceptables et qui s'améliorent de plus en plus grâce au développement croissant des capacités et des performances des calculateurs.

Concernant les outils de formalisation utilisés dans l'approche guidée par les données, et comme nous l'avons mentionné dans la section dédiée à l'état de l'art, différentes possibilités sont offertes. Les outils proposés concernent les réseaux de neurone, les filtres de Kalman, le filtre particulaire, les modèles de durée de vie, les modèles stochastiques, les modèles de régression, les méthodes Bayésiennes, les modèles de Markov cachés (HMMs : Hidden Markov Models) et les réseaux Bayésiens dynamiques (RBDs).

Dans notre cas, pour choisir les outils nous nous sommes appuyés sur deux critères : le premier est purement scientifique et le second est applicatif. Pour le critère scientifique, les outils retenus doivent permettre la prise en compte de l'incertitude des données de surveillance et des tests de vieillissement accéléré, la modélisation des phénomènes non linéaires, non stationnaires et stochastiques des dégradations, et la capacité d'actualisation de l'état de santé en fonction de nouvelles observations. Concernant le critère applicatif, les outils choisis doivent être intuitifs,

faciles d'utilisation, compréhensibles par les industriels et présentant des temps d'apprentissage hors ligne et d'inférence en ligne raisonnables. Parmi les outils qui répondent à ces critères, nous avons opté pour les RBDs, les machines à vecteurs de support pour la régression (SVR : Support Vector Regression) et les processus de Gauss pour la régression (Gaussian Process Regression : GPR). D'un côté, les RBDs généralisent les chaînes de Markov cachées et les filtres de Kalman et de l'autre côté, les SVRs et GPRs offrent plus de possibilités en termes de modélisation des incertitudes et des non linéarités que les méthodes de régression classiques.

4 Challenges, problématiques et verrous scientifiques

La réalisation d'un pronostic de défaillances précis et à horizon temporel significatif nécessite de relever différents défis scientifiques et technologiques. Ces défis sont liés aux classes de systèmes considérés, à la qualité des données à acquérir et traiter et à la granularité de la modélisation de l'état de santé du système concerné. Quelques-uns de ces défis sont mentionnés dans la littérature scientifique [4, 44, 56, 131], nous les avons complétées et résumés ci-dessous.

1. Prise en compte des données de fiabilité prévisionnelle et du retour d'expérience : lors de l'exploitation du système industriel, une quantité importante de données est enregistrée par des systèmes de surveillance dédiés, des opérateurs et du personnel de maintenance. Ces données peuvent être utilisées pour améliorer la connaissance *a priori* qu'on a du système et pour corriger ou affiner les modèles de comportement établis. Elles permettent également de mieux comprendre le comportement du système et ses interactions avec l'environnement dans lequel il évolue et enfin, de connaître ses limites.
2. Pertinence des données : la qualité des résultats de pronostic dépend fortement de la qualité des données utilisées à l'entrée des algorithmes développés. Les données, qu'elles soient issues de capteurs ou enregistrées par des opérateurs, doivent être choisies pour qu'elles soient représentatives de la dynamique du système et permettre le suivi de son état de santé tout au long de sa durée de vie. Les données doivent également être complètes, exemptes de toutes altérations et prêtes au traitement.
3. Prise en compte de conditions de fonctionnement variables : les modèles de pronostic proposés dans la littérature sont souvent restreints à des conditions de fonctionnement constantes et parfois limitées. Cependant, dans la pratique, il n'est pas rare qu'une machine tournante, par exemple, change de vitesse, de couple, d'environnement ou de contexte d'utilisation pendant son fonctionnement. Ainsi, si la machine est commandée par un variateur de vitesse, le passage d'une vitesse à une autre entraîne des variations de charge sur le rotor, des variations du courant dans le stator, de la surchauffe et autres phénomènes qui, s'ils ne sont pas pris en compte, peuvent compromettre la précision du pronostic.
4. Prise en compte des interventions de maintenance : lors d'une intervention de maintenance ou d'une inspection, les systèmes industriels peuvent subir des réparations ou être remis dans un état de fonctionnement qui n'est pas celui dégradé ou défaillant. Or, ce nouvel état est différent de l'état du système au moment de son acquisition (mode de fonctionnement nominal). Il est donc clair que l'intervention, ou l'inspection, modifie l'état du système, mais de quelle façon ? Il faut donc élaborer un modèle qui prenne en compte les interventions subies par le système de sorte à avoir une prédiction actualisée et précise de la durée de fonctionnement avant défaillance.
5. Modélisation du comportement du système : pour détecter à temps les premiers signes précurseurs d'une dégradation, localiser le ou les composants responsables et réaliser un pronostic précis, il est indispensable de construire des modèles de comportement du système

et de sa dégradation les plus fidèles possibles. Pour cela, il est nécessaire de bien choisir les outils de modélisation. Ainsi, la modélisation doit permettre de traduire les phénomènes physiques mis en jeu, représenter les interactions entre les composants du système et tenir compte des données utilisées et des moyens de calcul disponibles. Dans l'idéal, ces derniers doivent être les plus performants possibles.

6. Prédiction précise de durées de fonctionnement avant défaillances et à horizons temporels significatifs : pour réaliser un bon pronostic, le modèle de comportement à lui seul ne suffit pas. Il doit être complété par deux aspects : le premier concerne la mise en place de méthodes de détection de l'initiation des dégradations et le second est lié à la définition de seuils d'alarme. Ces seuils peuvent être de différents niveaux correspondant à différentes amplitudes de la dégradation (en allant des modes dégradés aux modes défaillants). Une fois ces deux aspects sont traités, la prédiction de la durée de fonctionnement peut être estimée en faisant des simulations du modèle et en comparant sa sortie aux seuils définis.

Chacun des challenges mentionnés ci-dessus soulève une ou plusieurs problématiques scientifiques et/ou technologiques auxquelles sont associés des verrous qu'il faut résoudre. Cela nécessite des compétences pluridisciplinaires en modélisation, traitement de données, en développement et programmation informatique et en ingénierie des systèmes, mais également du temps. Dans un souci d'efficacité et de clarté, nous nous sommes focalisés dans nos travaux de recherche sur quatre problématiques majeures. Elles sont décrites ci-dessous.

1. Choix des composants critiques et acquisition de données : pour réaliser le pronostic de défaillances d'un système, nous avons jugé judicieux de le faire sur ses composants critiques plutôt que sur son intégralité. En effet, dans la pratique, la défaillance d'un système peut être expliquée par la défaillance d'un ou de plusieurs de ses composants. Cependant, ces derniers n'ont pas tous la même criticité. À titre d'exemple, la défaillance du système d'affichage des numéros des sièges après le démarrage d'un train à grande vitesse n'affectera pas la disponibilité de ce dernier. En revanche, la défaillance d'un pantographe ou d'un moteur de traction aura des conséquences quasi instantanées sur la disponibilité du train. La première problématique concerne donc l'identification des composants critiques du système qui nécessitent une surveillance particulière et sur lesquels se focalisera le pronostic. Le verrou sous-jacent concerne la mise en place de tests de vieillissement accéléré de composants critiques pour fournir des données exploitables lors du processus de pronostic.
2. Extraction de caractéristiques et construction d'indicateurs de santé : les données recueillies sur le composant critique sont brutes et sont rarement directement exploitables par les algorithmes de PHM en général et ceux du pronostic en particulier. Elles doivent donc être traitées pour extraire des informations pertinentes qui renseignent sur l'état de santé du composant. Ces informations sont appelées caractéristiques (features). Dans la pratique, et selon les outils de modélisation utilisés, les signaux bruts ou les caractéristiques extraites peuvent être réduites ou combinées pour construire des indicateurs de santé dont la variation dans le temps traduit la variation de l'état du composant. La problématique associée concerne donc l'extraction de caractéristiques et la construction d'indicateurs de santé pertinents. Le verrou scientifique sous-jacent concerne l'obtention de caractéristiques et d'indicateurs monotones et permettant, d'un côté, de détecter les premiers signes précurseurs des dégradations et, de l'autre côté, de prédire avec suffisamment de temps les défaillances du composant.
3. Modélisation de la dégradation : les caractéristiques et indicateurs obtenus sont injectés à l'entrée d'outils de modélisation pour représenter les différents états de santé du composant. Cette problématique est capitale car une mauvaise modélisation conduit à de mauvais résultats de pronostic. Sa résolution nécessite de bien choisir les outils de modélisation.

Ces derniers doivent permettre de tenir compte des spécificités des données d'entrée et des conditions de fonctionnement du composant. Les verrous scientifiques liés à cette problématique concernent la compréhension des mécanismes de dégradation et de leur progression et le niveau de granularité de la modélisation (structure et ordre du modèle, dimension du vecteur d'état, etc.).

4. Évaluation de l'état de santé et prédiction de la durée de fonctionnement avant défaillance : pour prédire le RUL du composant, il est nécessaire d'estimer avec précision son état courant, de prédire son état futur et de définir des seuils de défaillance pertinents. Les états courant et futur résultent de l'exploitation du modèle de dégradation. Dans ce cas, la définition de seuils pertinents constitue le verrou scientifique principal de cette problématique. Les seuils choisis, combinés avec la sortie du modèle de dégradation, doivent permettre une prédiction précise du RUL.

5 Cadre général et hypothèses de travail

Dans les travaux résumés dans ce mémoire nous faisons l'hypothèse que le pronostic de défaillances sur un système industriel est équivalent à celui réalisé sur ses composants critiques. Nous appelons composant critique un composant qui présente un taux de défaillance élevé et/ou dont la défaillance entraîne l'indisponibilité du système dans lequel il est utilisé. Un ou plusieurs composants peuvent exister dans un même système. À titre d'exemples, dans un train on pourrait citer les roulements utilisés pour le guidage de la rotation de l'arbre du moteur électrique, l'induit de ce dernier, le mécanisme d'ouverture et fermeture des portes ou encore des composants du pantographe, notamment l'archet qui sert à capter le courant électrique de la caténaire. La décision de réaliser du PHM sur un seul composant ou sur plusieurs composants revient à l'exploitant du système. Notons que le but du PHM n'est pas de se substituer à la maintenance préventive des composants critiques, mais plutôt de l'optimiser en ne programmant des interventions de maintenance que lorsque cela est jugé pertinent. Dans le cas de plusieurs composants, nous supposons qu'ils sont indépendants. Cela nous permet de réaliser un pronostic sur chacun des composants séparément. On parle ainsi de pronostic orienté composant critique, comme le montre la figure 6. Pour le réaliser, on procède d'abord à l'identification des composants critiques. Ensuite, on définit pour chacun d'eux les grandeurs physiques à surveiller et qui sont susceptibles de renseigner sur l'évolution de leurs états de santé. Enfin, on choisit les capteurs à installer pour les surveiller et collecter des données représentatives de leurs dégradations.

Les contributions décrites dans ce mémoire reposent également sur un ensemble d'hypothèses résumées ci-dessous.

1. Une connaissance des composants du système, des interactions entre eux et des phénomènes physiques impliqués existe ou est possible à obtenir (données de retour d'expérience, experts du système, etc.). L'installation des capteurs nécessaires à la surveillance directe ou indirecte des composants critiques du système est également possible.
2. Les données de surveillance sont tout le temps disponibles. Les capteurs sont supposés fonctionner correctement et sans défaillances tout au long de la durée de vie du système. Dans le cas où un ou plusieurs capteurs tombent en panne, d'autres capteurs redondants sont supposés assurer la continuité des données.
3. L'évolution de la dégradation est supposée être observable, soit directement par un ou plusieurs capteurs, soit indirectement par la fusion d'informations données par des capteurs bien choisis et convenablement placés.

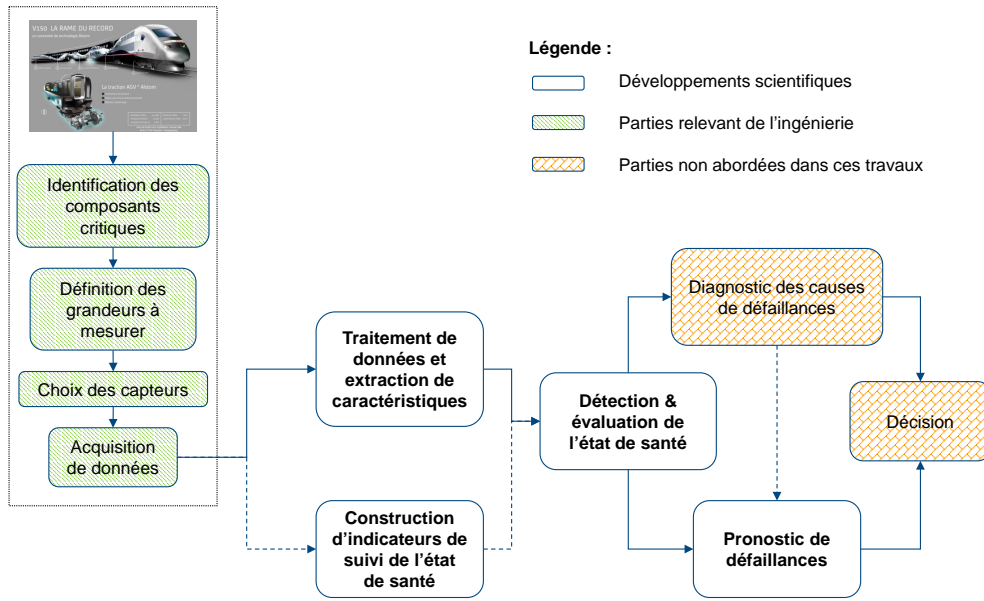


FIGURE 6: Pronostic orienté composants et guidé par les données.

4. Les données acquises sont suffisantes et représentatives des conditions de fonctionnement du composant et de ses états de santé.
5. Seules les défaillances engendrées par des dégradations progressives sont considérées, les défaillances soudaines ne sont pas prises en compte.
6. Les interventions de maintenance ne sont pas considérées pendant le pronostic et la dégradation est supposée aller jusqu'à son terme qui correspond à la défaillance du composant.

6 Principales contributions

La résolution des problématiques et des verrous associés annoncés dans la section 4 constitue les principales contributions de nos travaux de recherche. Ces contributions résultent en grande partie des travaux réalisés avec les Masters Recherche, les doctorant(e)s et les post-doctorants que j'ai encadrés ou co-encadrés. Elles sont résumées sur la figure 7 et détaillées dans quatre chapitres présentés après ce chapitre d'introduction générale.




FIGURE 7: Principales contributions et publications associées.

Nos contributions ont fait l'objet de quatorze articles publiés dans des revues internationales avec comités de lecture, deux chapitres d'ouvrage, dix-neuf articles publiés dans des conférences internationales avec comités de lecture et un article dans une conférence nationale avec comité de lecture. Ces publications sont listées dans la sous-section 4.6 (page 14) et résumées dans le tableau 1 (page 15).

7 Organisation de la partie activités de recherche

La partie dédiée à la synthèse des activités de recherche est organisée en quatre chapitres.

Le premier chapitre concerne le choix des composants critiques, la définition des grandeurs physiques à surveiller, le choix et l'emplacement des capteurs, l'acquisition et le prétraitement des données de surveillance. Les contributions présentées dans ce chapitre relèvent du domaine de l'ingénierie et sont en grande partie réalisées dans le cadre de nos collaborations industrielles.

Le deuxième chapitre est consacré au traitement des données de surveillance fournies par des capteurs installés pour renseigner l'utilisateur sur l'évolution dans le temps de l'état de santé du ou des composants critiques considérés. Il aborde l'extraction de caractéristiques pertinentes à partir des signaux bruts, la sélection de caractéristiques, la réduction de caractéristiques pour une meilleure représentation et interprétation et enfin, la construction d'indicateurs permettant de suivre l'état de santé du composant.

Le troisième chapitre concerne la modélisation de la dégradation du composant critique. Il présente une palette d'outils permettant de transformer les caractéristiques extraites et les indicateurs de santé construits dans le deuxième chapitre en modèles pertinents. Ces derniers représentent la variabilité des données d'entrée et tiennent compte de chaque type de composant et de ses conditions d'utilisation.

Enfin, le quatrième chapitre est consacré à l'exploitation des modèles générés dans le chapitre précédent pour l'estimation de l'état de santé du composant et la prédiction de son RUL. Nous y présenterons les notions de « health assessment » (suivi de l'état de santé), de seuils d'alarme ou de défaillance pour le calcul du RUL ainsi que les métriques de pronostic utilisées et les résultats issus de nos différentes contributions.

Chapitre 1

Choix des composants critiques et acquisition de données

1 Introduction

Ce chapitre présente une démarche globale permettant de générer des données de surveillance représentatives des phénomènes de dégradation des composants critiques et exploitables en PHM en général et en pronostic de défaillances en particulier. La démarche proposée relève du domaine de l'ingénierie et comporte trois étapes montrées sur la figure 1.1.




FIGURE 1.1: Étapes de la démarche proposée.

La première étape concerne le choix des composants critiques sur lesquels sera réalisé le pronostic. Cette étape est menée conjointement avec l'exploitant et/ou le fabricant du système dont l'expertise est précieuse. Le choix des composants critiques se fait sur la base des résultats de différentes analyses réalisées sur le système (analyses fonctionnelle et dysfonctionnelle, retour d'expérience, etc.). La deuxième étape est liée à la définition des grandeurs physiques à surveiller et le choix des capteurs à installer pour suivre dans le temps l'évolution des phénomènes de dégradation des composants. Dans le cas où des capteurs sont déjà présents sur le système, cette étape vise à vérifier leur pertinence par rapport aux tâches de PHM et éventuellement les compléter pour que les phénomènes d'intérêt soient observables. Enfin, la troisième étape traite de l'acquisition et du pré-traitement des données issues des capteurs. Son objectif est d'éliminer les erreurs qui pourraient affecter les données acquises. Cette étape vise également à sauvegarder les données selon des formats facilement exploitables par les algorithmes de traitement, à les filtrer et éventuellement les ré-échantillonner.

La démarche décrite dans ce chapitre a été appliquée sur différents types de systèmes notamment dans les domaines du transport ferroviaire, avec l'entreprise ALSTOM, et des machines d'usinage de précision, avec l'entreprise TORNOS. Au niveau laboratoire, elle a été exploitée dans nos travaux de recherche pour concevoir et réaliser, au sein de l'équipe PHM, une plateforme

expérimentale, appelée Pronostia, dédiée aux roulements à billes. Les données issues de cette plateforme nous ont permis de tester, vérifier et valider les algorithmes développés dans le cadre de nos travaux [17, 28, 91, 97, 100, 134]. Les données collectées ont également été mises à disposition de chercheurs et industriels pour mettre en concurrence leurs algorithmes de pronostic lors du « PHM data challenge » que nous avons organisé en 2012 dans le cadre de la conférence internationale sur le PHM sponsorisée par IEEE [1, 106].

Dans ce chapitre, nous présenterons la démarche proposée pour choisir les composants critiques, définir les grandeurs physiques à surveiller et acquérir des données représentatives des dégradations des composants. Cette démarche est ensuite appliquée sur un cas d'étude et utilisée pour concevoir et réaliser la plateforme expérimentale Pronostia.

2 Choix des composants critiques

Les composants critiques, dont un exemple est montré sur la figure 1.2, peuvent être donnés par le constructeur du système industriel concerné par le pronostic ou localisés par des opérateurs travaillant sur le système. Cependant, cette démarche est peu concrétisée dans la pratique. D'un côté, les constructeurs ne sont pas toujours les exploitants et communiquent rarement à leurs clients des informations sur les éléments critiques des machines qu'ils produisent. De l'autre côté, l'expertise d'un opérateur ne suffit pas à elle seule pour choisir avec pertinence les composants à surveiller.




FIGURE 1.2: Exemple de composants critiques.

Cette section présente l'approche proposée pour choisir les composants critiques d'un système industriel pour lequel on souhaite surveiller le comportement, suivre l'état de santé et pronostiquer des défaillances. Cette approche, dont les étapes sont résumées sur la figure 1.3, repose sur un ensemble d'outils existants et répandus dans la communauté de la Sécurité de Fonctionnement (SdF) et de la maîtrise des risques. Elle a été initialement mise en place dans le cadre de la thèse CIFRE¹ de D. A. Tobon-Mejia, thèse réalisée en collaboration avec l'entreprise ALSTOM Transport sur la nouvelle génération de moteurs AGV (Automotrices à Grande Vitesse). Elle a été ensuite affinée tout au long de nos travaux de recherche et de nos collaborations avec ALSTOM Transport sur d'autres types de systèmes telles que les portes de trains, mais également avec d'autres entreprises notamment TORNOS, une entreprise suisse concevant et fabriquant des machines d'usinage à commande numérique de haute précision. Dans le cadre de ces collaborations industrielles, réalisées sous forme de recherches partenariales, nous avons appliqué la démarche proposée sur différents systèmes. Malheureusement, les clauses de confidentialité

1. Conventions Industrielles de Formation par la REcherche

prises en place lors de ces collaborations ne nous permettent pas d'illustrer la démarche sur des exemples concrets et de montrer les résultats obtenus.




FIGURE 1.3: Étapes suivies pour le choix des composants critiques.

La première étape de l'approche consiste à décomposer le système industriel en plusieurs sous-systèmes, chacun ayant une fonction bien définie. Dans le cas d'un train par exemple, les sous-systèmes peuvent être le moteur de traction, le pantographe pour la captation de l'énergie électrique, les portes, le système de contrôle-commande, etc. Cette décomposition repose essentiellement sur l'expertise de l'exploitant du système, car c'est lui qui est en mesure de fixer le niveau de granularité de la décomposition. La deuxième étape de l'approche concerne la description technique de chacun des sous-systèmes. Il s'agit de recenser les composants principaux de chaque sous-système, leurs fonctions et les liens qui existent entre eux. Enfin, la troisième étape est une étape d'analyse quantitative et/ou qualitative des données et des connaissances fournies par le constructeur du système ou collectées durant l'exploitation. Cette analyse s'appuie sur différents outils formels issus de la SdF ou de la maîtrise des risques.

La SdF est une discipline répandue dans les secteurs de la défense, de l'aéronautique, du nucléaire, de l'espace et des transports [160]. Elle propose une riche palette de concepts, de méthodes et d'outils au service de l'utilisateur du système. Elle introduit quatre indicateurs connus sous l'acronyme de FMDS (Fiabilité, Maintenabilité, Disponibilité, Sécurité) et permet d'utiliser les connaissances *a priori* et *a posteriori* que l'on dispose d'un système afin d'identifier, entre autres, ses mécanismes de défaillance. Parmi les méthodes utilisées en sûreté de fonctionnement et maîtrise des risques, on peut citer le retour d'expérience, l'analyse préliminaire de risques, l'AMDEC (Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité), l'HAZOP (HAZard and OPerability study), les arbres de causes, les arbres d'événements et les arbres de défaillances (cf. tableau 1.1). Ces méthodes, bien documentées dans la littérature scientifique et répandues chez les industriels [83, 119, 158], diffèrent selon le type d'analyse (inductive ou déductive) et les informations/connaissances utilisées (quantitatives ou qualitatives).

Dans ce qui suit, nous nous intéresserons principalement à trois méthodes quantitatives permettant d'identifier la criticité des modes de défaillances et de choisir les composants critiques. Il s'agit du retour d'expérience, de l'AMDEC et de l'arbre de défaillances. En effet, ces trois méthodes sont complémentaires pour rechercher les modes de défaillance d'un système donné. Dans un premier temps, l'AMDEC permet d'identifier de manière inductive les possibles modes de défaillance et leur criticité. Puis, l'évaluation des scénarios dangereux par un arbre de défaillances permet de compléter les résultats de l'AMDEC. Ces résultats, pondérés par les données issues du retour d'expérience, sont utilisés pour identifier les défaillances potentiellement critiques et les composants qui en sont responsables.

2.1 Retour d'expérience

D'après Y. Verot [160], le principe du retour d'expérience est d'améliorer la connaissance d'un système par l'observation, le recueil, l'analyse et le traitement des informations relatives au

Technique	Type d'analyse	Type de donnée	Idée principale
Retour d'expérience	Déductive	Quantitative	Alimenter la connaissance du système à partir du vécu
Analyse préliminaire des risques (APR)	Inductive	Qualitative	Identifier a priori les risques à étudier
AMDEC	Inductive	Quantitative	Évaluer les conséquences des défaillances
Arbre de causes	Déductive	Qualitative	Organiser les événements ayant contribué à un accident (défaillance)
Arbre d'événements	Inductive	Quantitative	Évaluer les conséquences possibles d'un événement
Arbre de défaillances	Déductive	Quantitative	Évaluer les scénarios d'une défaillance potentielle

TABLE 1.1: Principales méthodes utilisées pour l'évaluation et la maîtrise de risques.

fonctionnement réel du système et de son impact sur son environnement. Le retour d'expérience est une démarche consistant à apprendre de ce qui s'est passé et de ce qui se passe pour améliorer le système. Il a pour but d'actualiser ou de compléter la connaissance *a priori* qu'on a du système. La démarche générale de retour d'expérience peut être résumée en cinq étapes :

1. Analyse de tout événement anormal.
2. Recherche des causes et enchaînements.
3. Recherche des enseignements.
4. Définition des mesures correctives.
5. Diffusion des connaissances capitalisées.

Le retour d'expérience est souvent réalisé en réaction aux signaux émis par le système lors de ses différentes phases d'exploitation (démarrage, fonctionnement, arrêt, etc.) lorsqu'un dysfonctionnement est détecté en regard des conditions normales. Pour l'identification des modes de défaillance, le retour d'expérience peut être complété par une évaluation *a priori* (audits, recherche d'anomalies, etc.) afin de détecter, avant que l'événement ne survienne, les éléments ou les conditions qui pourraient y donner naissance ou y conduire. Il s'agit de détecter et d'analyser *a priori* les conditions ou les actions porteuses de risques [160].

2.2 AMDEC

L'AMDEC est une méthode inductive qui part des défaillances élémentaires des composants pour en déduire ce qui en résulte et donc à quelles situations, dues à ces défaillances, on peut s'attendre. De plus, elle ajoute une dimension d'évaluation de la gravité de ces situations. Elle consiste à identifier et évaluer l'impact des défaillances des composants du système sur celui-ci, ses fonctions et son environnement.

D'une manière générale, l'AMDEC identifie les problèmes auxquels est exposé un système industriel. Elle permet notamment :

- d'évaluer la gravité des situations dangereuses possibles ;
- d'évaluer globalement les risques dus aux défaillances des composants ;
- d'identifier et de hiérarchiser les faiblesses du système ;
- d'identifier les actions de maintenance nécessaires ;
- d'évaluer l'intérêt des modifications de la conception ou de maintenance (surveillance) pour réduire ces risques ;

- de définir des mesures d’exploitation adaptées aux fonctionnements dégradés ;
- de hiérarchiser l’importance des règles d’exploitation et de maintenance ;
- et d’intégrer, dans une vision globale du système, les compétences des spécialistes travaillant sur ce dernier.

Pour la mise en œuvre de l’AMDEC, il est nécessaire de réunir trois conditions. D’abord, il faut savoir décomposer l’ensemble du système étudié en composants d’un niveau de finesse tel qu’à chaque composant on sache associer tous les modes de défaillance qui peuvent l’affecter. Ensuite, il faut connaître les fonctionnements du système pour pouvoir décrire ce qui se passe quand apparaît un mode de défaillance d’un composant et suivre la chaîne de la cause vers les conséquences. Enfin, il est nécessaire de respecter et de suivre la procédure définie dans les normes internationales CEI 60812 [3] et BS 5760-5 [24] relatives à l’AMDEC.

L’AMDEC constitue un outil efficace pour l’analyse des systèmes qui, combinée avec un retour d’expérience, peut servir à identifier les modes de défaillance les plus fréquents et les plus critiques.

2.3 Arbre de défaillances

De façon similaire à l’AMDEC, l’arbre de défaillances est généralement construit dans le cadre d’une étude *a priori* d’un système. Il évalue de façon synthétique l’ensemble des combinaisons d’événements qui, dans certaines conditions, produisent une défaillance donnée (événement redouté) qui constitue le point de départ de l’étude. Construire un arbre de défaillance revient à répondre à la question suivante : comment une défaillance donnée peut-elle arriver ? Ou encore : quels sont les enchaînements possibles qui peuvent aboutir à une défaillance donnée ?

Un arbre de défaillance est généralement présenté de haut en bas. La ligne la plus haute ne comporte que la défaillance dont on cherche à décrire comment elle peut se produire. Chaque ligne inférieure détaille la ligne supérieure en présentant la ou les combinaisons susceptibles de produire la défaillance à laquelle elles sont rattachées [160]. Ces relations sont représentées par des portes logiques « OU » ou « ET ».

Les arbres de défaillances sont particulièrement utiles pour faire la synthèse de tout ce qui peut conduire à une défaillance, d’évaluer l’effet de cette dernière sur le système et de comparer les conséquences des mesures qui peuvent être envisagées pour réduire l’occurrence de la défaillance (ou de l’événement redouté). Ils permettent aussi d’évaluer la probabilité d’occurrence de la défaillance à partir des combinaisons des probabilités des événements élémentaires qui peuvent la produire. Cette méthode, de la même manière que l’AMDEC, est complétée par un retour d’expérience, car la nature *a posteriori* de ce dernier permet d’affiner les probabilités ainsi que d’identifier d’autres modes de défaillance n’ayant pas été considérés lors de la construction *a priori* de l’arbre.

En conclusion, l’agrégation des trois méthodes présentées précédemment permet d’identifier les modes de défaillances, les relations entre ces derniers et les composants physiques qui sont associés et qui peuvent donc être considérés comme critiques.

3 Grandeurs physiques à surveiller

La surveillance et le suivi de l’état de santé des composants critiques peuvent être réalisés à partir de l’analyse des valeurs prises par certaines de leurs grandeurs physiques. Le choix de

Domaine	Grandeur physique
Thermique	Température, flux thermique, dissipation thermique
Électrique	Tension, courant, résistance électrique, inductance, capacité, constante du diélectrique, charge, polarisation, champs électrique, fréquence, puissance, niveau de bruit, impédance
Mécanique	Longueur, aire, volume, déplacement, vitesse, accélération, débit, force, couple, densité, masse volumique, raideur, frottement, pression, émissions acoustiques
Chimique	concentration chimique, réactivité
Humidité	humidité relative, humidité absolue
Biologique	PH, concentration de molécules biologiques, micro-organismes
Optique	Intensité lumineuse, phase, longueur d'onde, polarisation, réflectance, transmittance, indice de réfraction, amplitude, fréquence
Magnétique	Champs magnétique, moment magnétique, perméabilité, direction, position, distance

TABLE 1.2: Exemples de grandeurs physiques à surveiller [30].

ces dernières est donc primordial. Cela nécessite une connaissance fine et approfondie des liens causaux entre la variation des grandeurs physiques et l'initiation et l'évolution des dégradations. Un mauvais choix peut conduire soit à des non détections, soit à de fausses alarmes qui, dans les deux cas, pourraient avoir des conséquences catastrophiques (accidents, explosions, déraillements, etc.). À titre d'exemple, la mesure des vibrations axiales sur un roulement d'une machine tournante renseigne sur la présence de défauts au niveau des billes ou des cages, par contre la mesure de l'humidité autour du roulement aura moins de pertinence sur la détection de défauts. Le choix des grandeurs physiques à surveiller nécessite des compétences pluridisciplinaires du fait de la diversité des phénomènes physiques présents dans les systèmes industriels et dans leurs composants critiques. Dans ce choix, les expertises du constructeur et de l'exploitant du système sont précieuses et doivent être prises en compte. Le tableau 1.2 donne un aperçu des grandeurs à surveiller en fonction de certains phénomènes physiques.

4 Acquisition et stockage de données

Après l'identification des composants critiques et la définition des grandeurs physiques à surveiller, l'acquisition, le stockage et le pré-traitement des signaux issus des capteurs constituent la troisième étape de la démarche proposée. Elle permet de fournir des données fiables et prêtes au traitement par les différents modules du PHM. Elle est généralement assurée par une chaîne d'acquisition dont un exemple de structure est montré sur la figure 1.4.

Une chaîne d'acquisition a pour rôle d'assurer les fonctions suivantes [9] :

- extraction de l'information liée à chacune des grandeurs physiques à surveiller et transformation en signaux électriques au moyen de capteurs ;
- transformation des signaux électriques délivrés par les capteurs sous forme de charges, de courants ou autres signaux en tensions électriques ;




FIGURE 1.4: Structure d'une chaîne d'acquisition [9].

- traitement analogique (amplification et filtrage) des signaux afin d'éviter leur dégradation par le bruit et les parasites ;
- sélection d'un signal parmi tous les signaux disponibles au moyen d'un multiplexeur ;
- conversion des signaux analogiques en suites numériques exploitables par un ordinateur. Cette conversion est réalisée par un échantillonneur-bloqueur suivi d'un convertisseur analogique numérique.

Les parties capteurs, acquisition et stockage des données sont brièvement décrites ci-dessous.

4.1 Capteurs

Les capteurs sont les premiers éléments d'une chaîne d'acquisition. Ils ont pour rôle de traduire les valeurs des grandeurs physiques en signaux électriques pouvant être traités par le module d'acquisition. Ils sont caractérisés par différents attributs telle que l'étendue de mesure, la fidélité, la justesse, la précision, la sensibilité, la résolution, la rapidité, etc.

4.1.1 Types de capteurs

Il existe différents types de capteurs fonctionnant selon différents principes physiques et fabriqués selon différentes technologies. L'objectif ici n'est pas de décrire le principe de fonctionnement de chaque capteur, mais plutôt de recenser les capteurs et leurs domaines d'utilisation. Plus de détails sur ces catégories peuvent être trouvés dans [9]. On distingue les capteurs générateurs de force électromotrice, les capteurs générateurs de courant, les capteurs générateurs de charge, les capteurs résistifs, les capteurs inductifs, les capteurs capacitifs et les capteurs pour milieux fortement perturbés. La figure 1.5 montre quelques exemples de ces capteurs.



FIGURE 1.5: Exemples de capteurs de force et d'accéléromètres à quartz.

4.1.2 Choix des capteurs

Le choix des capteurs est une tâche qui demande des compétences pluridisciplinaires en raison de la diversité des phénomènes physiques mis en jeu dans les composants. Cette tâche nécessite la prise en compte d'un ensemble de contraintes et de considérations dont les plus importantes sont données ci-dessous.

- Performances : ensemble des caractéristiques métrologiques des capteurs (précision, linéarité, sensibilité, etc.).
- Fiabilité : les capteurs doivent être choisis de telle sorte qu'ils ne doivent pas réduire ou altérer la fiabilité du système dans (ou sur) lequel ils seront installés.
- Coût : ce critère doit être pris en compte lors du choix des capteurs pour que la solution proposée soit rentable et compétitive.
- Nombre et emplacement : le nombre de capteurs dépend de chaque application et des objectifs attendus (redondance de capteurs pour la surveillance et la conduite du système, couverture de tous les mesurands, estimation d'un mesurande par une ou plusieurs mesures, etc.). L'emplacement des capteurs est aussi un critère qui doit être considéré lors du choix afin de garantir que les mesures obtenues correspondent bien aux mesurands ciblés.
- Type de fixation : différentes solutions de fixation sont possibles (collage, vissage, magnétique ou adhésive) et le choix de chacune d'entre elles dépend de la qualité des mesures attendues, du composant à surveiller, du milieu dans lequel fonctionne le composant, etc.
- Dimensions et poids : la taille, la forme, le poids et le boîtier de chaque capteur sont des éléments à prendre en compte pour ne pas influencer les mesures à réaliser et respecter les contraintes d'encombrement.
- Encombrement : dans certaines applications, l'accès aux mesurands peut être difficile, voire impossible. Les capteurs doivent donc être choisis en connaissance des contraintes d'encombrement ; des solutions de télémessure peuvent être proposées pour les cas difficiles d'accès.
- Environnement : les capteurs subissent les variations des paramètres de l'environnement qui les entoure (températures extrêmes, taux d'humidité élevé, présence de rayonnements nucléaires et électromagnétiques, etc.). Dans ce cas, les capteurs doivent être choisis de telle sorte que les mesures fournies ne soient pas altérées par les variations des paramètres environnementaux.

4.2 Acquisition, prétraitement et stockage de données

Un système d'acquisition est généralement composé d'une carte d'acquisition, d'un ordinateur, d'un logiciel dédié et éventuellement d'un disque dur externe pour le stockage de gros volumes de données et pour un post-traitement (figure 1.6).




FIGURE 1.6: Structure simplifiée et illustrée d'une chaîne d'acquisition.

Acquisition de données

Cette tâche est réalisée au moyen de cartes d'acquisition. Ces dernières ont pour rôle d'acquérir (entrées) et de délivrer (sorties) des signaux. On parle ainsi de cartes à entrées/sorties. Les entrées et sorties peuvent être analogiques et/ou numériques selon l'application envisagée. Il existe deux types de cartes : des cartes enfichables dans l'unité centrale de l'ordinateur et des cartes externes (ou enfichables dans un boîtier externe dédié). La plupart des cartes destinées à l'acquisition de données intègrent des conditionneurs, filtres, multiplexeurs et convertisseurs analogiques numériques. L'utilisateur n'a qu'à connecter les sorties des capteurs à l'entrée de ces cartes. Les cartes sont également fournies avec des drivers facilitant leur utilisation (choix des fréquences d'échantillonnage, transferts programmés ou par interruption, gestion des flux de données vers le disque dur, etc.). Enfin, des logiciels spécialisés, gratuits ou payants, permettent la communication avec la carte pour l'acquisition, le stockage, l'affichage et le traitement des données acquises. Parmi ces logiciels, le plus répandu est le logiciel graphique LabView de National Instrument.



FIGURE 1.7: De gauche à droite : carte d'acquisition de vibrations, de température et châssis externe à l'ordinateur.

Le choix d'une carte d'acquisition est primordial et conditionné par plusieurs critères : vitesse de transfert des données, mémoire tampon, nombre de voies, types de conditionneurs, bande passante, etc.

Échantillonnage

Lors de l'acquisition des données, le choix de la fréquence d'échantillonnage est déterminant. En théorie, et afin d'éviter toute perte d'informations entre la sortie du capteur et la sortie de la carte d'acquisition, la fréquence d'échantillonnage F_e doit être supérieure ou égale à deux fois la fréquence maximale F_h du signal à échantillonner (condition de Shannon) :

$$F_e \geq 2.F_h \quad (1.1)$$

Cependant, dans la pratique, et selon les limites de la carte d'acquisition, la fréquence d'échantillonnage peut aller jusqu'à 24 fois la fréquence maximale du signal à échantillonner.

Stockage et pré-traitement des données

Les signaux acquis par une carte d'acquisition sont dans un premier temps sauvegardés sous forme de fichiers de données avec différents formats (généralement .txt, .csv ou .tdms). Des exemples de formats de fichiers de données sont montrés sur la figure 1.8. En plus des données de mesure, ces fichiers peuvent contenir des informations concernant les conditions de fonctionnement du composant critique (profils de charge, vitesse de rotation, température de l'enceinte où se déroulent les expérimentations, etc.).

9,39,39,65664,0.552,-0.146	8 47 5 196914 0.050 -0.253
9,39,39,65703,0.501,-0.48	8 47 5 196953 0.165 -0.140
9,39,39,65742,0.138,0.435	8 47 5 196992 0.125 0.542
9,39,39,65781,-0.423,0.24	8 47 5 197031 0.157 -0.261
9,39,39,65820,-0.802,0.02	8 47 5 197070 0.421 0.081
9,39,39,65859,-0.364,0.112	8 47 5 197109 0.683 -0.278
9,39,39,65898,0.326,0.296	8 47 5 197148 0.656 -0.297
9,39,39,65937,0.874,-0.366	8 47 5 197187 0.804 0.002
9,39,39,65976,0.885,-0.369	8 47 5 197226 0.685 -0.286
9,39,39,66015,0.257,0.538	8 47 5 197265 0.291 0.042
9,39,39,66054,-0.388,0.045	8 47 5 197304 0.407 1.082
9,39,39,66093,-0.602,0.32	8 47 5 197343 0.726 0.579
9,39,39,66132,0.006,-0.287	8 47 5 197382 0.804 -0.743
9,39,39,66171,0.557,-0.154	8 47 5 197421 0.650 -0.438

FIGURE 1.8: Exemples de formats de fichiers de données : à gauche un format .csv, à droite un format .xlsx.

Dans un deuxième temps, les données sauvegardées sont vérifiées pour détecter d'éventuelles erreurs ou absence d'échantillons. En effet, il arrive parfois que certaines parties des matrices de données soient remplacées par des caractères ou valeurs nulles ou encore complètement vides. Dans ces cas, le prétraitement consiste à remplacer les caractères ou les données manquantes par d'autres valeurs numériques (moyennes sur une fenêtre de données précédentes, zéros, etc.). Les données collectées peuvent également subir d'autres types de prétraitement tel que le filtrage pour enlever le bruit ou le ré-échantillonnage pour diminuer leur taille. Enfin, les données vérifiées et corrigées sont stockées dans différents fichiers dans le disque dur de l'ordinateur dédié aux expérimentations et/ou dans un disque dur externe offrant une grande capacité de stockage. Les données peuvent ensuite être affichées, analysées ou traitées par des logiciels ou autres algorithmes spécialement développés pour l'application.

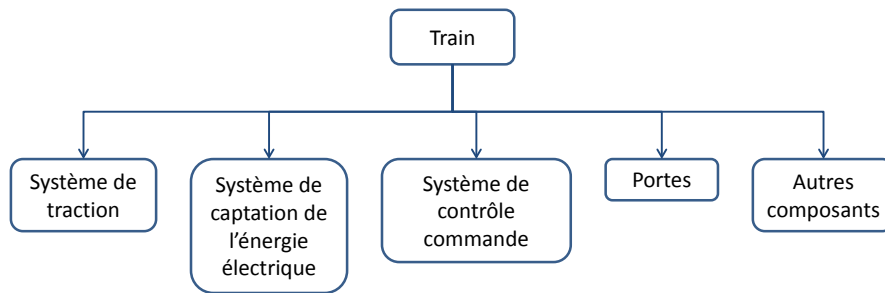


FIGURE 1.9: Sous-systèmes d'un train.

5 Cas d'étude

Afin d'illustrer la démarche présentée dans les sections précédentes, nous proposons de considérer comme cas d'étude un train de transport de voyageurs. Ce dernier est un système complexe composé de différents sous-systèmes (figure 1.9) chacun assurant un ensemble de fonctions élémentaires, toutes concourant à la réalisation de la fonction globale du train qui est de transporter des passagers d'un point *A* à un point *B* en toute sécurité et confort.

Si on considère le système de traction, ce dernier est composé d'un bogie sur lequel est monté un moteur électrique (figure 1.10).

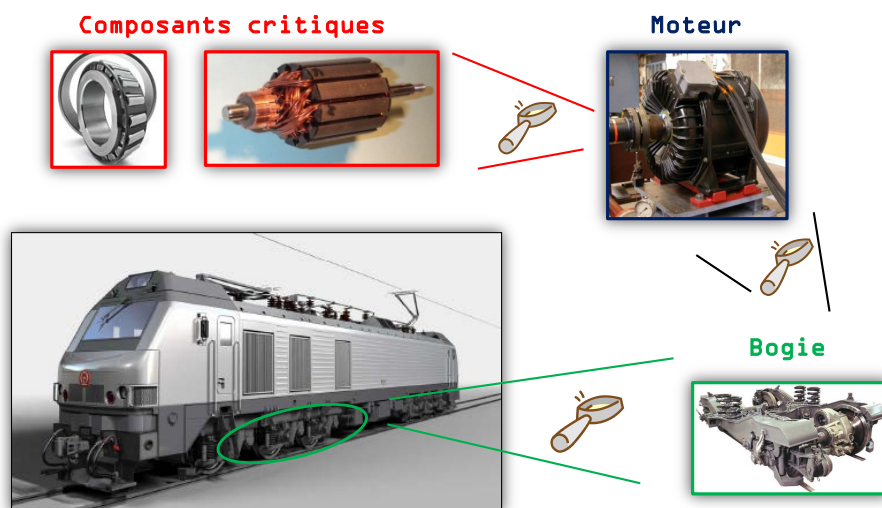


FIGURE 1.10: Composants critiques d'un moteur de train.

Dans le cas d'un moteur, dont le rotor est à base d'un aimant permanent et le stator à base d'un bobinage, l'analyse des données du retour d'expérience obtenues par le service de maintenance d'ALSTOM Transport a permis de conclure que le roulement et le stator sont les composants qui subissent le plus de défaillances. Ce résultat est concordant avec la distribution des défaillances présentée sur le tableau 1.3. Dans ce dernier, les analyses effectuées par le *Electric Power Research Institute (ERPI)* et des chercheurs en fiabilité des machines électriques conduisent aux roulements comme composants les plus défaillants.

Ce retour d'expérience, complété par l'analyse AMDEC réalisé par le bureau d'études de la même entreprise, montre que les roulements ont un niveau de criticité élevée (3 sur 4) [146]. Ce résultat est dû au fait que les roulements possèdent une probabilité de défaillance moyenne et

	Pourcentage de défaillance %				
	Bloch and Geitner [20]	O'Donnell [111]	IEEE - ERPI [71]	Albrecht <i>et al.</i> [6]	Alstom transport
Roulements	41	45 - 50	45 - 55	41	40
Stator	37	30 - 40	26 - 36	36	38
Arbre	10	8 - 12		9	10
Autres	12			14	12

TABLE 1.3: Distribution des défaillances des moteurs asynchrones.

une gravité jugée comme critique, car leur dysfonctionnement peut suffire à provoquer l'arrêt de l'arbre du moteur qui entraîne à son tour le blocage du train sur la voie ferrée.

Les défaillances des roulements du moteur peuvent être occasionnées par différentes causes. Cependant, la plupart de ces défaillances sont liées à l'usure, à une mauvaise lubrification, à la présence de corps étrangers et aux passages de courants électriques résiduels. Ces événements ont tous comme conséquence la dégradation des éléments du roulement jusqu'à sa rupture si une intervention n'est pas réalisée à temps.

Les résultats de cette étude ainsi que les différentes collaborations que nous avons nouées avec les industriels nous ont conduit à concevoir et réaliser une plateforme expérimentale dédiée au PHM de roulements à billes au sein de notre équipe de recherche.

6 La plateforme expérimentale Pronostia

Différentes plateformes expérimentales (ou de simulation) dédiées aux tâches de PHM sont proposées dans la littérature. Elles concernent différents composants critiques tels que les engrenages [63], les outils de coupe et les machines d'usinage [38, 125, 144, 174], les pompes hydrauliques [115], les composants électroniques, les turboréacteurs et les batteries [144] et les roulements [35, 75, 110, 130, 137, 170]. Dans ce dernier cas d'application, la majeure partie des plateformes proposées simule les défaillances en les créant artificiellement (au moyen de fortes décharges électriques dans les roulements par exemple), ce qui ne correspond pas toujours à la réalité. On connaît ainsi le défaut provoqué et on travaille à le détecter automatiquement. Pour réaliser des scénarios proches de ce qui se passe dans la pratique, nous avons conçu et réalisé la plateforme Pronostia. Sur cette dernière, les roulements subissent des vieillissements accélérés sans défauts initiaux. On obtient ainsi des données représentatives des différents stades de dégradation des roulements.

Pronostia (figure 1.11-(a)) est destinée aux tests et à la validation de méthodes de détection, diagnostic et pronostic de défaillances de roulements à billes. Son objectif principal est de fournir des données expérimentales réelles caractéristiques de la dégradation du roulement étudié durant toute sa durée de vie utile. En l'occurrence, des roulements à une seule rangée de billes de type NSK 6804DD sont utilisés pour les tests (figure 1.11-(b)). La plateforme a été conçue pour maintenir ce roulement dans des conditions de fonctionnement sévères. Ceci permet de conduire des expérimentations en quelques heures et d'obtenir ainsi un grand nombre d'historiques de données en quelques semaines.




FIGURE 1.11: Banc d'expérimentation de roulements Pronostia : (a) principaux éléments du banc et (b) le roulement NSK 6804DD utilisé.

6.1 Principe de fonctionnement

Le principe de base, permettant d'obtenir une usure prématurée du roulement, consiste à exercer sur ce dernier une contrainte radiale réglable dans une plage allant de 0 à 10000 N, tout en étant potentiellement stable durant la totalité de l'expérimentation. Ce système permet donc d'appliquer 2,5 fois la contrainte radiale maximale, ce qui permet d'accélérer la dégradation. La vitesse de rotation est aussi réglable dans une plage allant de 0 à 2000 tr/min.

La dégradation générée dans le roulement est le produit des contraintes appliquées par deux systèmes séparés. D'un côté, un vérin pneumatique permet d'appliquer une charge sur un bras de levier qui transmet la force radiale au roulement. Puis, d'un autre côté, l'arbre permet d'assurer la rotation de la bague interne du roulement dans l'intervalle de vitesse $[0, 2000]$ tr/min mesurée par un capteur de vitesse.

L'actionneur de la force radiale est un vérin pneumatique (figure 1.12-(a)) dont la pression d'ali-




FIGURE 1.12: Éléments du banc permettant d'appliquer la contrainte radiale : (a) vérin pneumatique et (b) régulateur de pression proportionnel.

mentation est délivrée par un régulateur proportionnel (figure 1.12-(b)), lui-même alimenté par un réseau pneumatique général sous une pression de 7 bars. La force ainsi délivrée par le vérin est indirectement appliquée à la bague extérieure du roulement par l'intermédiaire de sa bague de bridage. L'effort est transmis via un système de démultiplication sous la forme d'un bras de levier en rotation qui applique la charge augmentée sur un axe relié à la bague de bridage (figure 1.13-(b)). Cette dernière inclut un capteur d'effort qui permet de mesurer la charge appliquée au roulement testé.

Deux accéléromètres et une sonde de température sont utilisés pour surveiller la dégradation




FIGURE 1.13: Système de démultiplication et de transmission de la charge : (a) vue sur le banc de test et (b) détail des éléments sur la chaîne de transmission.

du roulement. Les mesures d'accélérométrie et celles de température sont échantillonnées respectivement à 25,6 kHz et 10 Hz.

Une centrale d'acquisition, reliée à un ordinateur via une liaison USB, permet d'acquérir les mesures des différents capteurs présents sur la plateforme. Enfin, une application développée sous Labview permet de formater, horodater, enregistrer et visualiser les signaux acquis pour une utilisation en PHM.

6.2 Expérimentations réalisées

Plusieurs campagnes expérimentales ont été réalisées sur la plateforme Pronostia. Ces expérimentations diffèrent par leurs durées totales et par leurs profils de charge. Des exemples d'expérimentations sont donnés dans le tableau 1.4.

Les expérimentations sont arrêtées lorsqu'une augmentation excessive des vibrations est consta-

Condition de fonctionnement	Expérimentation	Vitesse (tr/-min)	Charge (N)	Durée	Mode de défaillance
1	1	1800	4000	3H25	BI, BE
	2	1800	4000	6H50	BE
	3	1800	4000	6H48	BE
	4	1800	4000	6H16	BE
	5	1800	4000	1H00	BE
	6	1800	4000	1H12	BE, BI
2	1	1650	4200	1H12	BI
	2	1650	4200	5H25	BE
	3	1650	4200	2H05	BE
	4	1650	4200	6H26	BE
	5	1650	4200	1H57	BI, BE
	6	1650	4200	2H11	BE

BE = Bague Externe, BI = Bague Interne

TABLE 1.4: Récapitulatif des tests réalisés sur la plateforme Pronostia.

tée sur les mesures. Ces valeurs sont ensuite prises pour des seuils de défaillance. Des exemples de défaillances constatées sur les roulements sont montrés sur la figure 1.14.

Si on compare les durées de vie expérimentales des roulements à celles obtenues théoriquement, en utilisant la loi L_{10} décrite dans la norme DIN ISO 281 [2], on obtient une durée de 555 minutes pour la condition de fonctionnement 1 et de 521 minutes pour la condition 2.



FIGURE 1.14: Exemples de dégradations : (a) dégradation de la bague externe et (b) dégradation de la bague interne.




FIGURE 1.15: Exemple de signaux vibratoires bruts obtenus de la plateforme Pronostia.

Pour la première condition, nous avons trois cas ayant duré entre 6 et 7 heures, deux autour d’une heure et un de 3 heures et 25 minutes. Ces durées sont différentes des 9 heures et 15 minutes (555 minutes) estimées par la loi L_{10} . Ce résultat montre que les estimations théoriques ou statistiques diffèrent de celles réellement constatées. Il montre également l’intérêt de procéder à une surveillance continue pour collecter des données représentatives des dégradations des composants critiques et de leurs durées de vie réelles.

6.3 Exemples de signaux obtenus

Pendant les expérimentations, les signaux délivrés par les capteurs placés à proximité du roulement sont enregistrés avec différentes cadences. La fréquence d’échantillonnage pour les accéléromètres est fixée à 25,6 kHz et celle des capteurs de température à 10 Hz. Cependant, après acquisition des signaux, un ré-échantillonnage a été appliqué. Ainsi, pour les vibrations, pour chaque second enregistrée (25600 points) seul un dixième a été utilisé (2560 points). On a fait de même pour la température, au lieu des 600 points par seconde on a pris 60 points par seconde seulement.

La figure 1.15 montre des signaux vibratoires issus des accéléromètres installés sur la plateforme Pronostia. Comme on peut le constater, les roulements n’ont pas tous la même durée et ne se dégradent pas de la même façon. Tout le challenge est alors de pouvoir extraire à partir de ces signaux bruts, des caractéristiques et des indicateurs pertinents permettant de suivre la progression de la dégradation et d’anticiper l’instant de défaillance.

7 Conclusion

Dans ce chapitre, nous avons abordé la problématique de génération de données de surveillance fiables et exploitables en PHM. Pour la résoudre, nous avons proposé une démarche qui repose sur trois étapes : 1) le choix des composants critiques, 2) la définition des grandeurs physiques à surveiller et le choix des capteurs à installer et 3) l'acquisition, le stockage et le prétraitement des données. Cette démarche, qui relève du domaine de l'ingénierie, est générique et destinée aux systèmes industriels. Elle a pour finalité la collecte de données représentatives du comportement des composants critiques et de leurs dégradations. Ces données seront ensuite utilisées pour la surveillance du système, la détection, le diagnostic et le pronostic de ses défaillances et l'aide à la décision pour assurer son maintien en conditions opérationnelles.

La première étape de la démarche concerne le choix des composants critiques du système sur lesquels on souhaite réaliser le PHM. Ces composants sont obtenus par la combinaison d'outils formels, utilisés en sûreté de fonctionnement et en maîtrise des risques, et de l'expertise du fabricant et/ou de l'exploitant du système. Cette expertise est indispensable, car elle permet de décomposer le système en sous-systèmes puis en composants avec un niveau de granularité pertinent, de donner les fonctions des composants, de mettre en évidence les liens fonctionnels et causaux qui existent entre eux et d'identifier les modes de défaillances, de leurs causes et de leurs conséquences.

La deuxième étape est liée à la définition des grandeurs physiques à surveiller et au choix des capteurs. Les grandeurs physiques sont obtenues à partir de l'analyse des modes de défaillances identifiés dans l'étape précédente. L'obtention de ces grandeurs nécessite également des connaissances pluridisciplinaires en électricité, mécanique, thermique, hydraulique, etc. Ces compétences sont essentielles à la compréhension des mécanismes de dégradation des composants et permettent de mieux cibler les grandeurs à suivre dans le temps et éviter de fausses surveillances (grandeurs n'ayant pas de liens avec les modes de défaillances envisagés). Le choix des capteurs est réalisé en fonction des grandeurs physiques identifiées et d'autres considérations tel que l'encombrement ou les spécifications techniques (précision, sensibilité, utilisation en milieu perturbé, etc.). Les capteurs doivent être bien placés pour garantir l'observabilité des phénomènes de dégradation, mais également en nombre suffisant pour assurer la redondance matérielle en cas de pannes d'un ou de plusieurs d'entre eux.

La troisième étape concerne l'acquisition, le stockage et le prétraitement des données de surveillance. Elle consiste à spécifier les caractéristiques techniques du système d'acquisition (types et nombre de voies, fréquence d'échantillonnage, types de conditionneurs, mémoire tampon, logiciel d'acquisition, etc.), de définir le format de stockage et les prétraitements à effectuer pour garantir des données fiables et exploitables par les algorithmes de PHM.

La démarche proposée dans ce chapitre a été appliquée avec succès sur des systèmes réels dans le cadre de nos collaborations industrielles avec les entreprises ALSTOM (moteur AGV, portes de trains et pantographes) et TORNOS (machines à commande numérique pour l'usinage de haute précision). Cette démarche a également été capitalisée pour concevoir et réaliser la plateforme expérimentale Pronostia au sein de notre équipe de recherche. Cette plateforme permet de tester et vérifier nos approches et algorithmes de PHM avec plus de liberté et de flexibilité. Les données qui y sont issues sont mises à disposition de chercheurs et industriels et ont fait l'objet d'un « PHM challenge » que nous avons organisé en 2012 en collaboration avec la société IEEE lors de la conférence internationale sur le PHM qui s'est tenue à Denver aux États Unis.

Le choix des composants critiques et l'acquisition de données de surveillance sont des tâches

qui relèvent davantage de l'ingénierie. Elles sont néanmoins déterminantes pour la réussite du processus de PHM. En effet, un mauvais choix de composants, de grandeurs à surveiller ou de spécification du système d'acquisition conduit à des résultats biaisés en détection, diagnostic, pronostic et décision.

Toutefois, la mise en œuvre de ces tâches sur un système complexe n'est pas aisée. Cela nécessite des compétences pluridisciplinaires et une collaboration étroite avec le constructeur et/ou l'exploitant du système qui possède des informations précieuses. Ces tâches soulèvent de nombreuses difficultés à résoudre pour avoir des données représentatives, complètes, fiables et exploitables en PHM. Ces difficultés concernent la compréhension du système et des interactions entre ses composants, l'analyse des données d'exploitation et de retour d'expérience, la compréhension des mécanismes de dégradation, le choix du système d'acquisition et la prise en compte des contraintes applicatives (encombrement, non accessibilité à la mesure, etc.). Elles concernent autant les systèmes en conception que les systèmes en exploitation, avec toutefois plus de pondération pour le second cas. En effet, dans le premier cas, les fonctionnalités de PHM peuvent être intégrées dès la conception (on parlera alors de « PHM designed »), tandis que dans le second cas, la non accessibilité à la mesure de certaines grandeurs, par exemple, peut être un frein au développement du PHM, même si parfois des solutions basées sur l'observabilité peuvent être envisagées.

Les données collectées et prétraitées dans ce chapitre seront utilisées dans le chapitre suivant pour extraire des informations pertinentes permettant de suivre la progression de la dégradation du composant critique.

Chapitre 2

Traitement de données

1 Introduction

Ce chapitre est consacré au traitement des données de surveillance fournies par les capteurs installés sur les composants critiques du système industriel. Ces données, qui sont des observations de l'état de santé du composant, cachent souvent des informations pertinentes sur le déclenchement et la progression des dégradations (figure 2.1). Par conséquent, leur exploitation directe en PHM n'est pas aisée. Il est donc nécessaire de les traiter pour révéler leur contenu et permettre d'estimer à tout instant l'état de santé du composant.




FIGURE 2.1: Signal vibratoire obtenu de la plateforme Pronostia.

Dans la suite de ce chapitre, nous nous intéresserons à quatre problématiques (cf. figure 2.2) : 1) extraction de caractéristiques, 2) réduction de caractéristiques, 3) sélection de caractéristiques et 4) construction d'indicateurs de santé (communément appelés Health indicators dans la communauté PHM).

L'extraction de caractéristiques a pour but de transformer les signaux bruts en d'autres signaux dans différents domaines (temporels, fréquentiels et temps-fréquence). Ces nouveaux signaux sont alors appelés caractéristiques (features en anglais). Comme exemples de caractéristiques, on peut

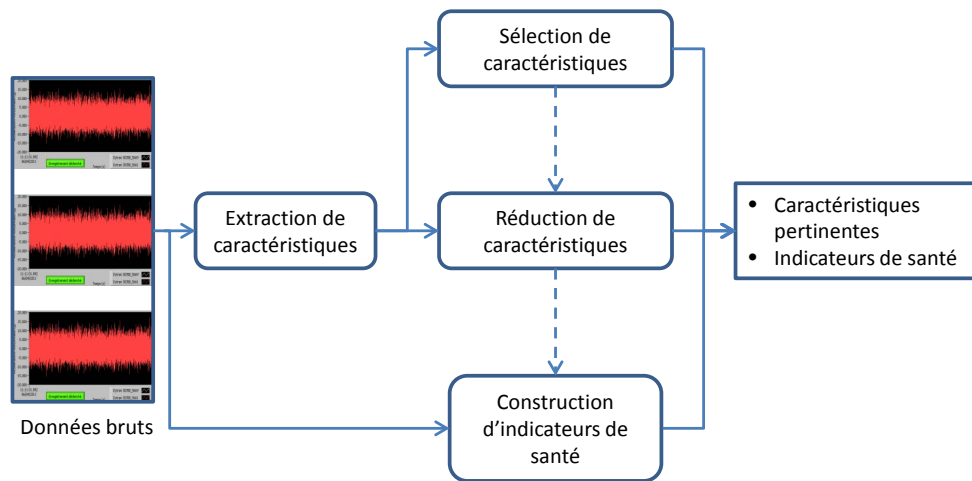


FIGURE 2.2: Extraction, sélection et réduction de caractéristiques et construction d'indicateurs de santé.

citer la moyenne du signal brut, son kurtosis, son asymétrie (skewness), son analyse spectrale, etc. Les caractéristiques extraites doivent permettre de rendre compte de la dynamique de la dégradation du composant critique étudié. Leur extraction requiert une bonne connaissance *a priori* des phénomènes physiques (chocs, fissures, fatigue, etc.) que subit le composant durant son utilisation. En outre, les caractéristiques extraites dépendent de l'usage qu'on en fait et des outils qu'on met en œuvre pour les modéliser. En effet, les caractéristiques utilisées en détection de défaillances peuvent être différentes de celles employées en diagnostic et/ou en pronostic. Dans le cas de l'approche de pronostic guidée par les données, la connaissance physique peut être obtenue ou complétée par les experts du domaine concerné. Cependant, dans la pratique, cette expertise peut manquer. On a alors tendance à extraire un nombre important de caractéristiques, ce qui rend leur représentation et visualisation difficiles. Pour contourner cette situation, on projette les caractéristiques dans un espace de dimension plus petite (généralement de deux ou trois) que celle de l'espace d'origine, tout en gardant le maximum de variance dans les données. On parle ainsi de réduction de caractéristiques. La représentation dans deux ou trois dimensions permet ainsi de distinguer les différents stades de dégradation du composant. On peut également sélectionner parmi toutes les caractéristiques extraites initialement celles qui sont les plus pertinentes au regard de critères préalablement établis. Cela permet de ne garder qu'un nombre réduit de caractéristiques.

Les indicateurs de santé sont des signaux construits soit à partir des données brutes, soit à partir des caractéristiques extraites. Dans les deux cas, leur construction nécessite généralement plusieurs étapes de traitement (fusion de données, filtrage, extraction de résidus, etc.).

Différents travaux sur l'extraction, réduction et sélection de caractéristiques ainsi que sur la construction d'indicateurs de santé sont proposés dans la littérature scientifique [59, 64, 110, 173]. Cependant, ces travaux pris individuellement n'abordent pas toutes les étapes citées ci-dessus. La démarche que nous proposons dans ce chapitre se veut intégrée et met en œuvre des techniques novatrices comme la décomposition modale empirique (Empirical Mode Decomposition : EMD) et la transformée de Hilbert-Huang (Hilbert-Huang Transform : HHT).

Les contributions résumées dans ce chapitre sont, en grande partie, issues des travaux de thèse de Diego Alejandro Tobon-Mejia et d'Ahmed Mosallam et du post-doctorat d'Abdenour Soualhi. Elles ont fait l'objet de publications dans des revues [16, 17, 100, 134] et des conférences internationales avec actes et comités de lecture [90, 96].

2 Extraction de caractéristiques

Dans le cas du PHM, l'extraction de caractéristiques repose essentiellement sur des techniques issues du traitement du signal. Ces techniques peuvent être regroupées dans deux catégories principales selon que le signal à traiter est stationnaire ou non stationnaire [171]. Les signaux stationnaires sont caractérisés par des propriétés statistiques invariantes dans le temps. Pour ces signaux, on distingue deux groupes de techniques : le premier groupe génère des caractéristiques temporelles et le second groupe des caractéristiques fréquentielles. Concernant les signaux non stationnaires, ils sont caractérisés par des propriétés statistiques dépendantes du temps. Dans cette catégorie, les aspects temporel et fréquentiel sont tous les deux pris en compte lors de la génération de caractéristiques. La figure 2.3 donne un aperçu des techniques utilisées pour l'extraction de caractéristiques.

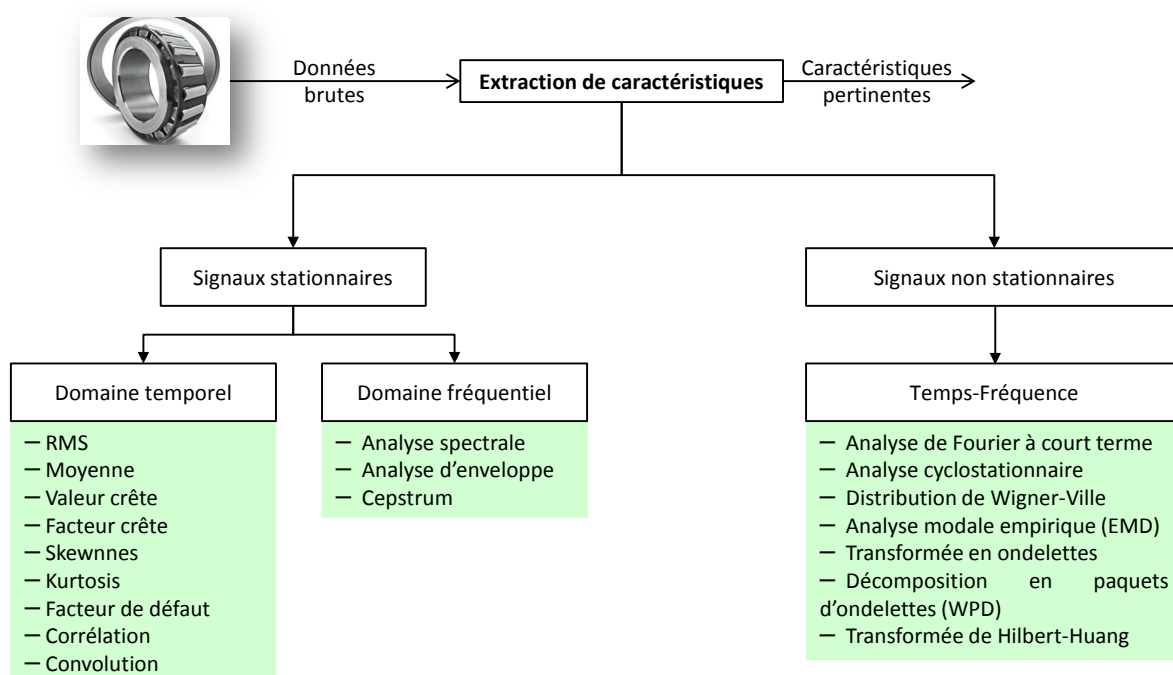


FIGURE 2.3: Techniques d'extraction de caractéristiques [171].

Les techniques d'analyse temporelle [45,69,76,136,140] sont les plus anciennes et les plus faciles à mettre en œuvre. Elles permettent d'extraire des caractéristiques temporelles des signaux bruts. Parmi ces caractéristiques, on peut citer la moyenne, le carré de la moyenne quadratique (Root Mean Square : RMS), la valeur pic, le kurtosis, le facteur de crête, etc. Leur utilisation suppose que l'apparition d'un défaut ou d'une dégradation conduit à une variation significative des paramètres statistiques du signal. Les caractéristiques extraites avec ces techniques peuvent être utilisées pour la détection de défauts, mais moins pour le diagnostic car elles ne permettent pas toujours d'identifier le composant responsable de l'anomalie constatée. En outre, ces caractéristiques génèrent souvent de fausses alarmes lorsque les signaux traités ne sont pas stationnaires. La présence de bruits peut également altérer les résultats et empêcher d'avoir des détections précoces des défauts.

L'analyse fréquentielle consiste à visualiser l'énergie du signal à différentes fréquences. En connaissant les conditions de fonctionnement du composant critique (vitesse, charge, géométrie des éléments constitutifs, etc.), on peut extraire des caractéristiques permettant d'isoler les défauts qui

peuvent survenir sur le composant. Ces caractéristiques sont aussi appelées signatures fréquentielles. La technique la plus utilisée est la transformée de Fourier. Cependant, ce type d'analyse ne convient pas aux signaux non stationnaires qui représentent la majeure partie des signaux issus de dégradations. Cette analyse ne prend pas également en compte la dimension temporelle. Dans ce cas, même si elle permet d'isoler le défaut, elle ne dit pas à quel instant ce dernier est apparu.

Les techniques du domaine temps-fréquence sont principalement utilisées pour traiter des signaux non stationnaires. On y distingue la transformée de Fourier courte [7], la distribution de Wigner-Ville [21], l'analyse en ondelettes notamment la décomposition en paquets d'ondelettes (Wavelet Packet Decomposition : WPD) [77,107,110], la décomposition modale empirique [49] et la transformée de Hilbert-Huang [47,48,50]. La transformée de Fourier courte segmente le signal en fenêtres temporelles et applique ensuite la transformée de Fourier sur les fenêtres obtenues. Cependant, la taille des fenêtres est difficile à choisir. Concernant la distribution de Wigner-Ville, elle conduit parfois à l'apparition de termes croisés, ce qui peut conduire à des analyses erronées. La décomposition en paquets d'ondelettes (WPD) consiste à utiliser une paire de filtres passe-haut et passe-bas. Ces filtres permettent de réaliser une division du contenu fréquentiel du signal brut en deux composantes (ou paquets), l'une contient les hautes fréquences et l'autre les basses fréquences. Puis, ces paquets sont successivement injectés dans les filtres pour séparer de nouveau en deux l'espace fréquentiel. Cette opération permet d'atteindre des niveaux de décomposition assez fins qui permettent de suivre l'évolution des fréquences, tout en gardant une bonne résolution pour les phénomènes rapides et lents grâce à l'utilisation d'une ondelette mère et des paramètres d'échelle et de translation [77,110,151,172]. La WPD peut être utilisée pour la détection et le suivi de dégradations [165], mais son efficacité dépend fortement de la qualité des signaux traités. Pour pallier à tous ces inconvénients, l'une des techniques la plus efficace pour l'analyse des signaux non stationnaires est la transformée de Hilbert-Huang [50,60,116]. Elle s'appuie sur deux techniques : l'EMD [39,43,49] et la transformée de Hilbert. L'EMD décompose le signal en fonctions modales intrinsèques (Intrinsic Mode Functions : IMFs) représentant les modes oscillatoires du signal. Ensuite, la transformée de Hilbert est appliquée sur chaque IMF pour extraire les fréquences instantanées et les amplitudes instantanées. La transformée de Hilbert-Huang permet ainsi une représentation tridimensionnelle (amplitude, fréquence, temps) de chaque mode oscillatoire du signal.

La suite de cette section présente quelques-unes des méthodes mises en œuvre dans nos travaux pour l'extraction de caractéristiques.

2.1 Caractéristiques temporelles

Elles concernent le calcul des paramètres statistiques du signal. Elles sont utilisées en classification, détection et diagnostic de défaillances où elles donnent des résultats acceptables. Cependant, leur utilisation en pronostic peut conduire à des résultats peu satisfaisants. Ceci est notamment dû au fait que les variations significatives liées à l'évolution des dégradations n'apparaissent que lorsque l'état du composant est très dégradé (proche de sa fin de vie), ce qui rend le pronostic moins opportun. Parmi les caractéristiques temporelles, on peut citer la moyenne, le carré de la moyenne quadratique (Root Mean Square : RMS) qui correspond à l'énergie moyenne du signal, la valeur de son pic qui peut renseigner sur la taille d'un défaut, le kurtosis qui caractérise l'aspect impulsif du signal, le facteur de crête qui mesure les augmentations rapides des vibrations dans les roulements et le skewness utilisé pour évaluer l'état de surface d'un composant. Le tableau 2.1 donne des exemples de caractéristiques temporelles et leurs formules mathématiques correspondantes. La figure 2.4 montre quelques caractéristiques obtenues à partir de signaux vibratoires issus des expérimentations réalisées sur la plateforme

Pronostia. Dans le tableau 2.1, s_t représente le signal brut, N le nombre de points enregistrés à l'instant t et σ_s l'écart-type du signal.

TABLE 2.1: Exemples de caractéristiques temporelles.

Caractéristique	Expression mathématique
Moyenne	$\frac{1}{N} \sum_{i=1}^N s_t(i) $
Carré de la moyenne quadratique	$\sqrt{\frac{1}{N} \sum_{i=1}^N s_t(i)^2}$
Valeur pic	$\max(s_t)$
Facteur de crête	$\frac{VP(s_t)}{RMS(s_t)}$
Skewness	$\frac{1}{N} \sum_{i=1}^N \left[\frac{s_t(i) - \bar{s}_t}{\sigma_s} \right]^3$
Kurtosis	$\frac{1}{N} \sum_{i=1}^N \left[\frac{s_t(i) - \bar{s}_t}{\sigma_s} \right]^4$




FIGURE 2.4: Exemples de caractéristiques temporelles obtenues sur des signaux vibratoires : à gauche le carré de la moyenne quadratique (RMS) et à droite le Kurtosis.

2.2 Caractéristiques fréquentielles

La technique la plus répandue pour extraire ce type de caractéristiques est la transformée de Fourier utilisée dans sa version discrète et rapide (Fast Fourier Transform : FFT). La transformée de Fourier discrète $S(k)$ d'un signal échantillonné $s(n)$ composé de N échantillons est donnée par l'expression suivante :

$$S(k) = \sum_{n=0}^{N-1} s(n) \cdot e^{-2i\pi k \frac{n}{N}} \quad (2.1)$$

avec

$$0 \leq k \leq N \quad (2.2)$$

La figure 2.5 montre le spectre de fréquence d'un signal vibratoire issu d'un roulement testé sur la plateforme Pronostia.

D'autres grandeurs issues de l'analyse spectrale peuvent être aussi utilisées pour la détection




FIGURE 2.5: Transformée de Fourier rapide obtenue à partir du signal vibratoire d'une durée de 3h25.

et la localisation de défaillances. C'est le cas de la densité spectrale de puissance qui correspond au carré du module de la transformée de Fourier, divisée par un temps d'intégration T .

$$\Gamma_s = \frac{|S|^2}{T} \quad (2.3)$$

La densité spectrale de puissance représente la répartition de la puissance d'un signal suivant les fréquences.

2.3 Caractéristiques temps-fréquence

Quatre techniques du domaine temps-fréquence ont été utilisées dans nos travaux pour la détection de défaillances, le suivi de l'état de santé de composants critiques et le pronostic de leurs durées de vie avant défaillance. Il s'agit de la transformée de Fourier à court terme, de la WPD, de l'EMD et de la transformée de Hilbert-Huang.

2.3.1 Transformée de Fourier à court terme

Elle est destinée aux signaux non stationnaires et consiste à appliquer la transformée de Fourier sur une portion (une fenêtre) glissante, supposée stationnaire, du signal. Le résultat est une représentation dans le temps du spectre de fréquence du signal. Les fréquences extraites peuvent

ainsi être utilisées pour détecter et diagnostiquer des défaillances de composants critiques, notamment des roulements. Cependant, pour obtenir des résultats fiables, il est indispensable de bien choisir la largeur de la fenêtre dans laquelle la transformée est réalisée. La figure 2.6 montre un résultat issu de la transformée de Fourier à court terme d'un signal de vibration prélevé sur un roulement testé sur la plateforme Pronostia.




FIGURE 2.6: Résultat de la transformée de Fourier à court terme réalisée sur un signal de vibration.

2.3.2 Décomposition en paquets d'ondelettes

La WPD a été développée et utilisée pour l'extraction de caractéristiques permettant de détecter et suivre des défauts de roulements [77, 110, 150, 172, 173]. Elle permet d'analyser les signaux non stationnaires et d'identifier les composantes fréquentielles d'un signal brut et son temps d'apparition. Elle fait appel à deux paramètres :

- un paramètre d'échelle qui joue le rôle de la fréquence dans la transformée de Fourier. Un paramètre d'échelle de petite valeur correspond à des fréquences élevées et inversement ;
- et un paramètre de translation qui joue le rôle de la position de la fenêtre dans la transformée de Fourier courte. Ce paramètre concerne l'axe de temps.

Comme on peut le constater sur la figure 2.7, la décomposition en paquets d'ondelettes peut être vue comme une arborescence. Dans cette représentation, le sommet de l'arbre est le signal brut, puis le premier niveau est le résultat de la première décomposition. Les niveaux suivants sont le résultat de l'application successive du processus de décomposition en paquets jusqu'à atteindre un niveau de granularité prédéfini. Selon [173], le niveau de décomposition peut être choisi en utilisant l'équation 2.4.

$$J_f \leq \log_2 \frac{F_s}{3F_d} - 1 \quad (2.4)$$

où :

J_f = niveau de décomposition.

F_s = fréquence d'échantillonnage.

F_d = fréquence de défaut maximale parmi les fréquences des éléments du roulement.




FIGURE 2.7: Exemple de décomposition en paquets d'ondelettes.

Les caractéristiques extraites en utilisant la WPD correspondent aux coefficients d'énergie des niveaux de décomposition (figure 2.8).




FIGURE 2.8: Pourcentage d'énergie du signal de l'accéléromètre vertical (1) et horizontal (2) pour les tests réalisés sous la condition numéro 1, après la décomposition en paquets d'ondelettes pour la bande 1-800 Hz.

2.3.3 Décomposition modale empirique

L'EMD [49] consiste à décomposer tout signal $x(t)$ en un ensemble de composantes appelées fonctions modales intrinsèques (Intrinsic Mode Functions : IMFs) représentant ses modes oscillatoires simples. Généralement, la composante qui a la période la plus petite (haute fréquence) est prise comme première IMF. Les composantes ayant les plus longues périodes (basses fréquences) sont ensuite décomposées dans l'ordre pour obtenir les IMFs suivantes. L'intérêt de cette technique réside dans le fait qu'il est possible d'isoler les bandes de fréquence contenant le défaut en ne retenant que les IMFs correspondantes. Un autre intérêt de cette méthode est le fait que tout signal peut être reconstruit en additionnant ses différentes IMFs. Ainsi, il est possible de filtrer le signal en éliminant les IMFs bruitées.

Une IMF est définie comme étant une fonction qui satisfait les conditions suivantes :

- les IMFs d'un signal $x(t)$ sont différentes les unes des autres ;

- chaque IMF possède le même nombre d’extremums et de passages par zéro. Il existe un seul extremum entre deux passages successifs par zéro ;
- dans toutes les valeurs du signal $x(t)$, le nombre d’extremums et le nombre de passages par zéro doivent être soit identiques soit différents d’un au plus ;
- à chaque instant t , la valeur moyenne de l’enveloppe définie par le maximum local et l’enveloppe définie par le minimum local est proche de zéro.

L’EMD décompose le signal $x(t)$ en quatre étapes :

1. Identifier tous les maximums locaux et les relier entre eux par une ligne cubique pour former l’enveloppe supérieure.
2. Répéter la procédure pour les minimums locaux pour construire l’enveloppe inférieure. Les enveloppes supérieure et inférieure doivent couvrir toutes les données du signal entre elles.
3. La valeur moyenne des enveloppes supérieure et inférieure est notée m_{10} et est donnée par l’expression suivante :

$$m_{10}(t) = (x_{up}(t) + x_{low}(t))/2 \quad (2.5)$$

$x_{up}(t)$ est l’enveloppe supérieure et $x_{low}(t)$ l’enveloppe inférieure du signal $x(t)$. La différence entre le signal $x(t)$ et m_{10} donne la première composante (IMF) notée p_{10} (figures 2.9 et 2.10).

$$x(t) - m_{10}(t) = p_{10}(t) \quad (2.6)$$

Si p_{10} satisfait la condition d’une IMF, alors elle est considérée comme la première composante de $x(t)$.

4. Sinon, elle est prise comme signal d’origine et les étapes 1 à 3 sont répétées. La deuxième composante notée p_{11} est alors exprimée par l’équation suivante :

$$p_{11}(t) = p_{10}(t) - m_{10}(t) \quad (2.7)$$

Le processus résultant des quatre étapes précédentes est appelé tamisage (sifting en anglais) et il est répété jusqu’à un instant k sur p_{ik} , jusqu’à ce que la courbe moyenne, entre les enveloppes supérieure et inférieure, soit à tout point proche de zéro.

$$p_{1k}(t) = p_{1(k-1)}(t) - m_{1(k-1)}(t) \quad (2.8)$$

où $m_{1(k-1)}$ représente la moyenne des enveloppes supérieure et inférieure du signal $p_{1(k-1)}$.

La première composante (IMF) $c_1 = p_{1k}$ représente la meilleure échelle ou la composante de la plus petite période du signal $x(t)$. L’extraction de c_{1k} à partir de $x(t)$ génère un premier résidu noté r_2 .

$$r_2(t) = r_1(t) - c_1(t) \quad (2.9)$$

avec $r_1(t) = x(t)$. Le processus global de tamisage est répété n fois sur le signal r_1 pour obtenir les composantes (IMFs) successives, avec pour chacune une période croissante. Cela donne les n IMFs du signal $x(t)$ en utilisant l’équation suivante :

$$r_n(t) = r_{n-1}(t) - c_{n-1}(t) \quad (2.10)$$

Lorsque le signal r_n devient monotone à partir duquel aucune IMF ne peut être extraite, le processus de décomposition peut être arrêté. En utilisant les équations (2.9) et (2.10) il est possible de reconstruire le signal $x(t)$ en utilisant l’expression suivante :

$$x(t) = \sum_{j=1}^{n-1} c_j(t) + r_n(t) \quad (2.11)$$




FIGURE 2.9: Signal $x(t)$ et ses enveloppes supérieure et inférieure.




FIGURE 2.10: La première IMF extraite.

où la dernière composante r_n , considérée comme résidu, est la tendance moyenne du signal $x(t)$. Le processus d'extraction des IMFs est résumé sur la figure 2.11. Du haut en bas, les IMFs c_1, c_2, \dots, c_n comportent différentes bandes de fréquence. La bande de fréquence de chaque IMF est différente d'une IMF à une autre et change en fonction du signal $x(t)$.

La figure 2.12 montre deux allures du résidu obtenu par l'EMD sur deux roulements, l'un neuf l'autre dégradé.

2.3.4 Transformée de Hilbert-Huang

La transformée de Hilbert-Huang [47, 48, 50] a été utilisée dans différentes applications, tel que le traitement de signal biomédical [52, 53, 82], la géophysique [33, 161, 166], le traitement d'image [109], le diagnostic [8, 23, 84], mais peu en pronostic de défaillances. Dans nos travaux, nous l'avons utilisée pour extraire des caractéristiques pertinentes et pour suivre l'état de santé de roulements [134].

La transformée de Hilbert-Huang est réalisée en deux étapes. La première étape concerne la décomposition modale empirique [49]. La seconde étape concerne la transformée de Hilbert appliquée sur chacune des IMFs obtenues par l'EMD afin d'extraire les fréquences et les amplitudes instantanées du signal d'origine. Ces deux informations sont nécessaires pour calculer le spectre marginal de Hilbert. Le résultat de la transformée de Hilbert-Huang est une représentation en trois dimensions (amplitude - fréquence - temps) du signal.

La forme analytique d'une IMF notée $c_i^A(t)$, $1 \leq i \leq n$, est définie comme suit :

$$c_i^A(t) = c_i(t) + jc_i^H(t) = a_i(t) e^{j\theta_i(t)}, \quad 1 \leq i \leq n \quad (2.12)$$

où $c_i^H(t)$ est la transformée de Hilbert de l'IMF $c_i(t)$, c'est à dire :

$$c_i^H(t) = \frac{1}{\pi} P \int \frac{c_i(s)}{t-s} ds \quad (2.13)$$




FIGURE 2.11: Processus de décomposition en IMFs.

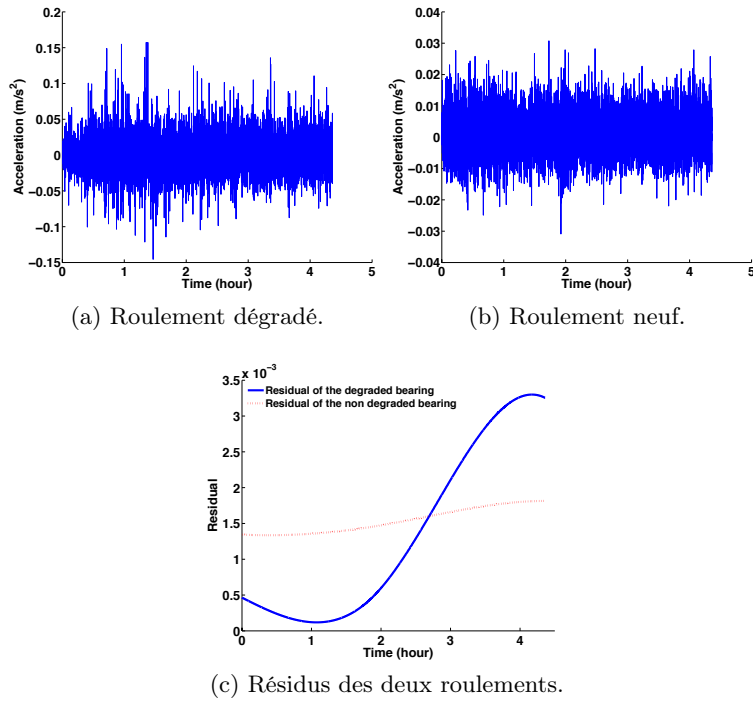


FIGURE 2.12: Variation du résidu de l'EMD en fonction de l'état du composant.

avec P la valeur principale de Cauchy.

Les coordonnées polaires de la forme analytique de l'IMF $c_i(t)$ permet d'obtenir l'amplitude

instantanée $a_i(t)$ et la phase instantanée $\theta_i(t)$ exprimées par l'équation suivante :

$$\begin{cases} a_i(t) = \sqrt{c_i^2 + c_i^{H^2}} \\ \theta_i(t) = \tan^{-1} \left(\frac{c_i^H}{c_i} \right) \end{cases} \quad (2.14)$$

La fréquence instantanée $f_i(t)$ peut être obtenue à partir de la phase instantanée $\theta_i(t)$ en utilisant l'équation suivante :

$$f_i(t) = \frac{1}{2\pi} \frac{d\theta_i(t)}{dt} \quad (2.15)$$

Enfin, le signal d'origine $x(t)$ peut être exprimé comme suit :

$$x(t) = \text{Re} \sum_{i=1}^n a_i(t) \exp \left[j 2\pi \int_0^T f_i(t) dt \right] \quad (2.16)$$

où Re est la partie réelle et T la longueur du signal $x(t)$. Le signal $x(t)$ est représenté par une distribution temps-fréquence. La transformée de Hilbert du signal $x(t)$ est définie par :

$$H(f, t) = \sum_{i=1}^n H_i(f, t) = \sum_{i=1}^n a_i^2(f_i, t) \quad (2.17)$$

où $H_i(f, t)$ correspond à la distribution temps-fréquence obtenue à partir de la i^{me} IMF du signal $x(t)$ et $a_i(f, t)$ combine l'amplitude $a_i(t)$ et la fréquence instantanée $f_i(t)$ de l'IMF.

La figure 2.13 montre un exemple de résultat obtenu par la transformée de Hilbert-Huang sur des données issues de la plateforme Pronostia.

3 Réduction de caractéristiques

Pour mieux visualiser et suivre la forme des caractéristiques, on les projette dans un espace de dimension réduite (généralement deux ou trois dimensions) en utilisant des méthodes de réduction linéaires ou non linéaires (figure 2.14). Dans nos travaux de recherche [16, 17, 97, 100], nous avons fait appel à trois méthodes : l'Analyse en Composantes Principales (ACP), l'ACP à noyau et l'Isomap (Isometric feature mapping). Dans cette section nous rappellerons brièvement ces méthodes et donnerons quelques résultats.

3.1 Méthode linéaire : analyse en composantes principales

L'ACP est une méthode de réduction linéaire utilisée pour la réduction et la visualisation de données ainsi que pour l'extraction de caractéristiques [19, 61]. Elle consiste à projeter les données à réduire dans un espace linéaire, de dimension plus petite, formé par les composantes principales de telle sorte que la variance des données projetées soit maximale. Le principe de l'ACP est illustré sur la figure 2.15.

Soit X une matrice de données (ou de caractéristiques) de dimension $M \times N$, où M représente le nombre d'observations et N les vecteurs de caractéristiques. On notera x_1, x_2, \dots, x_N les vecteurs colonnes de la matrice X . La visualisation et le traitement des caractéristiques (classification, clustering, régression, etc.) dans l'espace de représentation initial formé par les N vecteurs peut

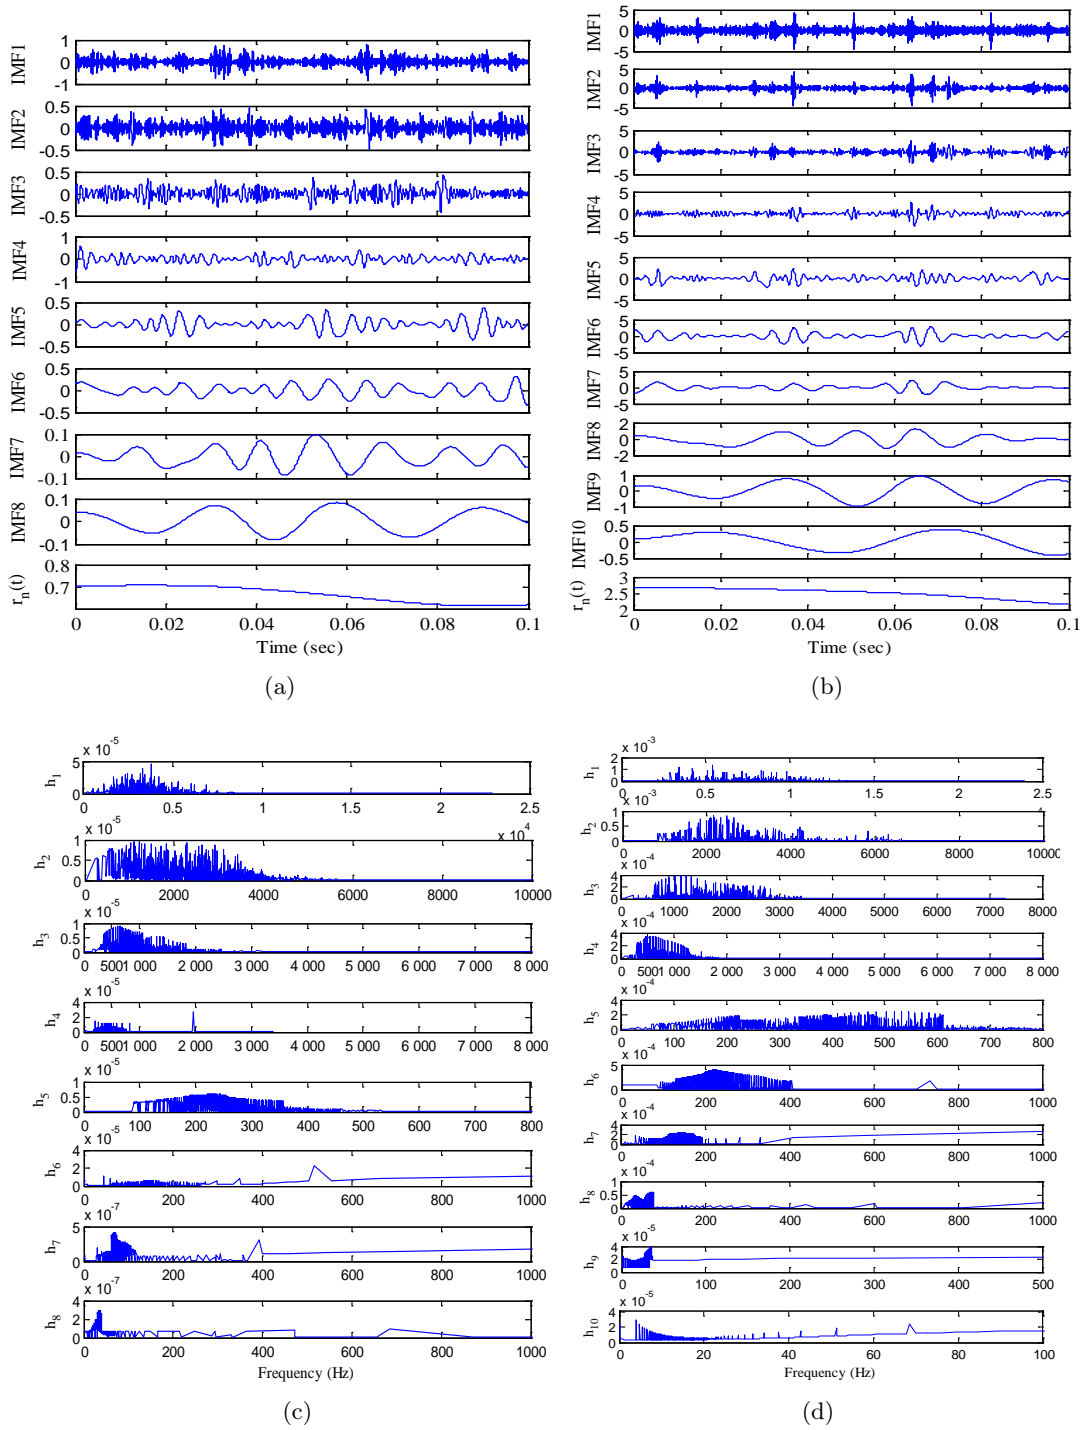


FIGURE 2.13: Exemples de résultats obtenus sur des signaux vibratoires issus de la plateforme Pronostia : (a) EMD d'un roulement neuf, (b) EMD d'un roulement défaillant, (c) HHT d'un roulement neuf et (d) HHT d'un roulement défaillant.

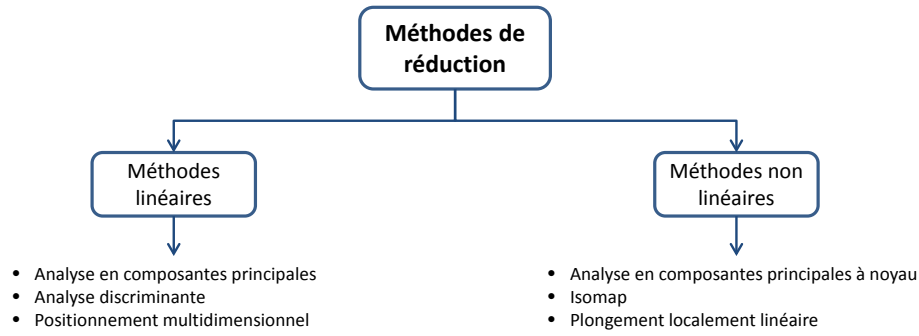


FIGURE 2.14: Méthodes de réduction de données.




FIGURE 2.15: Principe de l'analyse en composantes principales.

conduire à des résultats insatisfaisants. L'objectif de l'ACP est donc de projeter les caractéristiques dans un espace formé par p axes (composantes principales), avec $p < N$, afin de mieux les visualiser, traiter et analyser. Les étapes utilisées pour la réalisation d'une ACP sont résumées ci-dessous.

1. Calculer la moyenne μ_i , $i = 1, \dots, N$, de chaque vecteur colonne (caractéristique).
2. Centrer les caractéristiques en soustrayant la moyenne de chaque caractéristique de son vecteur correspondant : $x_i - \mu_i$, $i = 1, \dots, N$.
3. Calculer la matrice de covariance S de la matrice de caractéristiques centrées. La matrice de covariance est de dimension $N \times N$.
4. Calculer les valeurs propres λ_i , $i = 1, \dots, N$ ainsi que les vecteurs propres v_i , $i = 1, \dots, N$ de la matrice de covariance obtenue.
5. Ordonner les valeurs propres obtenues dans l'ordre décroissant (de la plus grande valeur à la plus petite valeur).
6. Garder les p vecteurs propres correspondant aux p plus grandes valeurs propres de telle sorte que la variance désirée à capturer soit égale ou supérieure à $\frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^N \lambda_i}$. Dans la pratique, la valeur minimale de variance retenue est de 75 %.
7. Normaliser les vecteurs propres retenus pour que leur norme soit égale à 1. Les vecteurs normalisés obtenus $u_i = \frac{1}{\sqrt{N\lambda_i}}v_i$, $i = 1, \dots, p$, représentent les composantes principales et forment le nouvel espace dans lequel les données sont projetées (nouvel espace de représentation).

La figure 2.16 montre un résultat de l'ACP obtenu sur des données vibratoires.




FIGURE 2.16: Réduction de trois à deux dimensions en utilisant l'ACP.

3.2 Méthodes non linéaires

3.2.1 ACP à noyau

Lorsque les données présentent une structure non linéaire, leur représentation et traitement dans l'espace de représentation d'origine, ou dans un espace de dimension réduite, conduit à des résultats non concluants. Pour y remédier, on cherche une transformation non linéaire ϕ qui projette les données dans un espace de dimension plus grande (appelé espace de re-description) dans lequel le traitement (partitionnement, classification, projection, etc.) devient possible. Ainsi, chaque donnée x_i est transformée en $\phi(x_i)$. On procède ensuite à une ACP dans l'espace de re-description, ce qui revient à faire une ACP non linéaire dans l'espace de représentation d'origine [19]. La figure 2.17 illustre le principe de transformation non linéaire des données. Les données d'origine (côté gauche) sont projetées par une transformation non linéaire ϕ dans un espace de re-description (côté droit). Les lignes vertes dans l'espace de re-description indiquent la projection linéaire des données transformées, elles correspondent à la projection non linéaire dans l'espace d'origine.




FIGURE 2.17: Principe de l'ACP à noyau, d'après [19].

Cependant, dans la pratique la fonction de transformation non linéaire ϕ n'est pas évidente à trouver. En outre, les calculs (souvent des produits scalaires $\langle \phi(x_i), \phi(x_j) \rangle$) sont difficiles, voire impossibles, à réaliser dans l'espace de re-description. Pour contourner cette difficulté, on fait appel à ce qui est appelé astuce de noyau (kernel trick) [19]. Le concept de noyau est introduit en 1964 par Aizermann *et al.* [5], il est ensuite rendu populaire par les travaux de Boser *et al.* sur les machines à vecteurs de support [22]. Il consiste à remplacer le calcul du

produit scalaire difficile à réaliser dans l'espace de re-description par une fonction noyau $k(x, y)$, continue, symétrique et semi-définie positive telle que $k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$. Ainsi, le résultat de la fonction noyau, facile à réaliser, revient à faire le produit scalaire dans l'espace de re-description. La preuve de cette équivalence de calcul a été formulée par le théorème de Mercer [94]. Dans la pratique, les fonctions noyau les plus utilisées sont :

- linéaire : $k(x_i, x_j) = x_i^T x_j$;
- polynômiale : $(x_i^T x_j + c)^d$, avec c une constante réelle et d un entier ;
- Gaussienne : $k(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$, avec σ une constante réelle.

Soit une matrice de données (caractéristiques) composée de M lignes (observations) et N colonnes (caractéristiques). La procédure permettant de remplacer la transformation non linéaire par une fonction noyau est résumée par les étapes suivantes.

1. Choisir une fonction noyau (linéaire, polynômiale ou Gaussienne).
2. Calculer le noyau (kernel), appelé aussi matrice de Gram : matrice de dimension $N \times N$ où la case ij contient le résultat de la fonction noyau entre les variables x_i et x_j (à noter que cette matrice est équivalente à l'espace de produit scalaire à réaliser dans l'espace de re-description).
3. Utiliser l'algorithme de traitement (classification, SVM, SVR, ACP, etc.) sur le noyau obtenu.
4. Le traitement réalisé dans ce noyau est équivalent au traitement à réaliser dans l'espace de re-description, qui lui est équivalent au traitement non linéaire dans l'espace d'origine.

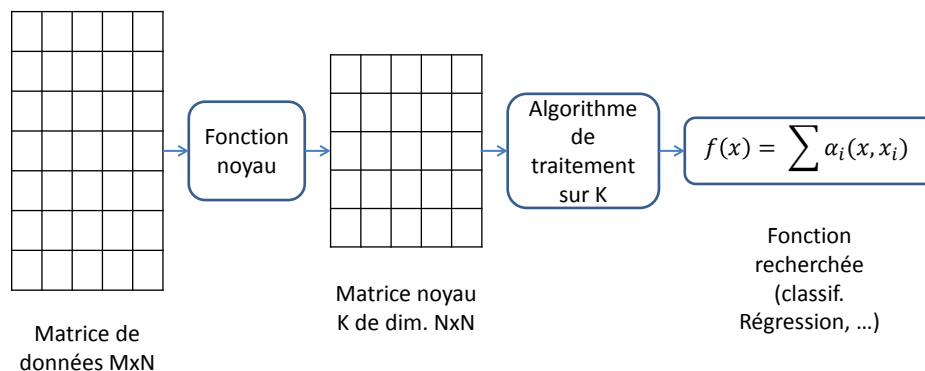


FIGURE 2.18: Résumé de la démarche de l'astuce du noyau.

L'ACP à noyau utilise l'astuce du noyau pour trouver les composantes principales sur lesquelles seront projetées les données transformées dans l'espace de re-description. Les étapes de l'ACP à noyau sont résumées ci-dessous.

1. Centrer les données de la matrice X .
2. Choisir une fonction noyau $k(x, y)$, généralement polynômiale ou Gaussienne.
3. Calculer la matrice de Gram K : matrice dans laquelle chaque case ij correspond à la valeur prise par la fonction $k(x_i, x_j)$.
4. Calculer la matrice de Gram modifiée : $\tilde{K} = K - 1_N K - K 1_N + 1_N K 1_N$ où 1_N est une matrice dont la valeur de chaque élément est égale à $1/N$.
5. Calculer les valeurs propres λ_i , $i = 1, \dots, N$ ainsi que les vecteurs propres v_i , $i = 1, \dots, N$ de la matrice K .

6. Ordonner les valeurs propres obtenues dans l'ordre décroissant (de la plus grande valeur à la plus petite valeur).
7. Garder les p vecteurs propres correspondant aux p plus grandes valeurs propres de telle sorte que la variance désirée à capturer soit égale ou supérieure à $\frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^N \lambda_i}$.
8. Normaliser les p vecteurs propres retenus pour que leur norme soit égale à l'unité : $u_i = \frac{1}{\sqrt{N\lambda_i}}v_i, i = 1, \dots, p$.
9. Projeter les données sur les vecteurs normés.

La figure 2.19 montre un résultat d'une ACP à noyau sur des données de vibration.




FIGURE 2.19: Résultat d'une ACP à noyau sur des données prises de Pronostia.

3.2.2 ISOMAP

L'Isomap [141] est une technique de réduction de dimension dont le but est de projeter la variété (espace topologique localement euclidien) formée par les données d'origine dans un espace de dimension réduite de telle sorte que les distances géodésiques entre les points de la variété soient préservées. L'Isomap prend comme entrées les distances $d_X(j, i)$ entre toutes les paires de points (observations de dimension M) de la matrice de caractéristiques X . Elle retourne en sortie les composantes des vecteurs y_p , avec $p = 1, \dots, P$ et $p < N$, formant l'espace de représentation de dimension réduite.

L'algorithme de mise en œuvre de l'Isomap comporte trois étapes [141], elles sont décrites ci-dessous et illustrées sur la figure 2.20.

1. Construire le graphe de voisinage : définir le graphe G à partir des données en connectant les points i et j si i est un des k plus proches voisins de j . La longueur de l'arête entre le point i et le point j est égale à $d_X(i, j)$.
2. Calculer la matrice $D_G = \{d_G(i, j)\}$ où $d_G(i, j)$ représente la distance du chemin le plus court entre le point i et le point j .
3. Construire l'espace de projection de dimension réduite : pour cela, on calcule d'abord la matrice $\tau_G = -\frac{HSH}{2}$ où S est la matrice des distances quadratiques ($S_{ij} = D_{ij}^2$) et $H = \delta_{ij} - \frac{1}{M}$ une matrice centrée dans laquelle δ_{ij} représente la fonction de Kronecker

$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{si } i \neq j \end{cases}$. Ensuite, on calcule et classe dans l'ordre décroissant les valeurs propres λ_n ($n = 1, \dots, N$). Puis, on retient les P valeurs propres les plus significatives et leur vecteurs propres correspondants. Enfin, on calcule les vecteurs formant l'espace de projection de dimension réduite (dimension égale à P) en utilisant la formule suivante : $y_p^i = \sqrt{\lambda_p} v_p^i$, où y_p^i est la i^{me} composante du vecteur y_p , λ_p est la p^{me} valeur propre et v_p^i est la i^{me} composante du vecteur propre v_p .




FIGURE 2.20: Illustration des étapes de l'Isomap, d'après [141] : (A) distance géodésique entre deux points, (B) graphes de voisinage et approximation de la distance géodésique par le chemin le plus court entre les deux points sur le graphe, (C) projection des données dans un espace de dimension 2 où la distance géodésique est maintenant approximée par la ligne droite.

La mise en œuvre de l'Isomap nécessite deux paramètres :

- k : nombre de voisins ou rayon r de la sphère contenant le voisinage ;
- d : nombre de valeurs propres significatives à retenir, c.à.d. la dimension de l'espace de projection.

Cette méthode a été appliquée avec succès sur les données du « PHM challenge 2010 » [145], relatives à l'usure des outils de coupe, et sur les données de la plateforme Pronostia [16, 17] (figure 2.21).

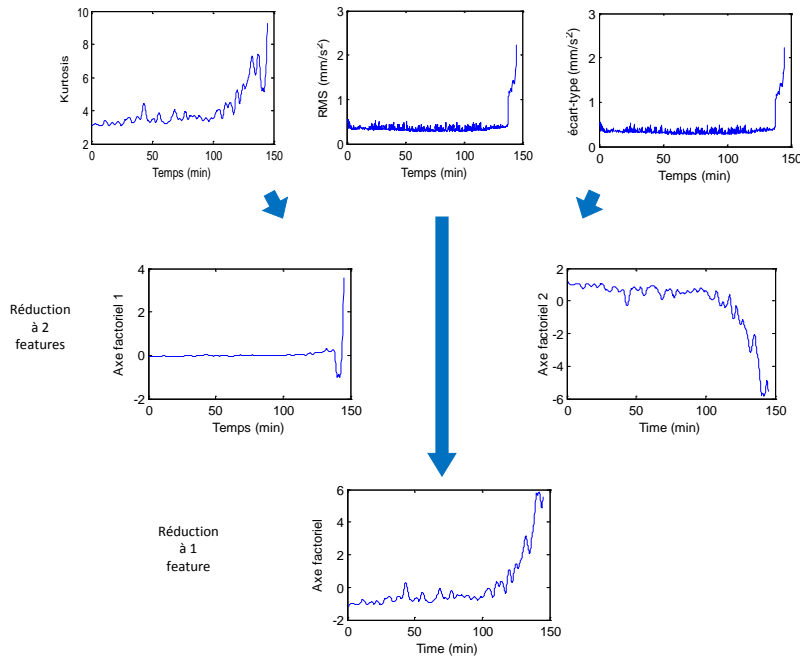


FIGURE 2.21: Extraction de deux, puis d'une caractéristique à partir du Kurtosis, du RMS et de l'écart-type en utilisant l'Isomap.

4 Sélection de caractéristiques

D'après [18], la sélection de caractéristiques consiste à choisir un sous-ensemble optimal de caractéristiques pertinentes à partir d'un ensemble initial selon un critère de performance prédéfini. Dans ce cas, on part de l'hypothèse que les caractéristiques extraites ne sont pas toutes utiles pour la modélisation et le suivi de la dégradation. En sélectionnant les caractéristiques pertinentes, on réduit leur nombre et on gagne en temps de calcul lors des phases d'apprentissage et d'exploitation.

La sélection de caractéristiques peut être réalisée selon deux approches [41, 101] : la notation des caractéristiques (features ranking) et le sous-ensemble de caractéristiques (subset selection).

La notation des caractéristiques consiste à donner une note (ou poids) à chaque caractéristique sur la base de critères prédéfinis (entropie, corrélation, information mutuelle, etc.) pour sélectionner les n meilleures d'entre elles. Cette approche est facile à mettre en œuvre. Cependant, le choix du paramètre n n'est pas toujours évident à définir.

La sélection du sous-ensemble consiste à déterminer automatiquement le plus petit sous-ensemble de caractéristiques toujours sur la base de critères prédéfinis.

Les méthodes de sélection de caractéristiques peuvent être classées en trois catégories [42] : les méthodes de filtrage (filter methods), les méthodes de couverture (wrapper methods) et les méthodes embarquées (embedded methods). La première catégorie évalue la pertinence d'une caractéristique ou d'un ensemble de caractéristiques pour une tâche donnée. La deuxième teste l'efficacité d'un algorithme sur des sous-ensembles de caractéristiques et retient celui qui donne le meilleur résultat. Enfin, la troisième considère la sélection comme faisant partie de la procédure d'apprentissage de l'algorithme utilisé pour réaliser une fonction désirée (partitionnement, classification, etc.).

Dans les travaux de thèse d'Ahmed Mosallam nous avons proposé un algorithme de sélection non supervisée de caractéristiques [100]. Cet algorithme commence par calculer une mesure d'incertitude symétrique par paires (pairwise symmetrical uncertainty) SU sur toutes les caractéristiques extraites. Cette mesure est définie par l'équation suivante :

$$SU(X, Y) = 2 \times \frac{I(X, Y)}{H(X) + H(Y)} \quad (2.18)$$

où $I(X, Y)$ est l'information mutuelle entre deux variables (caractéristiques) X et Y , et $H(X)$ et $H(Y)$ représentent l'information d'entropie pour chacune des variables. Ensuite, l'algorithme mesure la distance entre toutes les paires de variables en utilisant le partitionnement hiérarchique (hierarchical clustering), comme cela est montré sur la figure 2.22. Enfin, l'algorithme note chaque partition (cluster) en fonction de la qualité de l'information contenue dans les variables qui le composent. La figure 2.23 montre un exemple de caractéristiques sélectionnées en utilisant l'algorithme proposé.

5 Construction d'indicateurs de santé

Nous avons proposé dans les travaux de thèse d'A. Mosallam et du post-doctorant A. Soualhi deux approches pour construire des indicateurs de santé : la première approche repose sur la sélection/réduction de caractéristiques et la décomposition modale empirique [16, 17, 97] et la seconde approche est basée sur la transformée de Hilbert-Huang [134].




FIGURE 2.22: Dendrogramme obtenu à partir du partitionnement sur les distances de similarité par paire.




FIGURE 2.23: Exemple de deux groupes de caractéristiques : à gauche une forte corrélation entre trois variables et à droite une faible corrélation entre deux variables.

5.1 Indicateurs de santé obtenus par sélection - réduction et EMD

Les étapes de cette approche sont résumées sur la figure 2.24. Elles sont brièvement décrites ci-dessous.

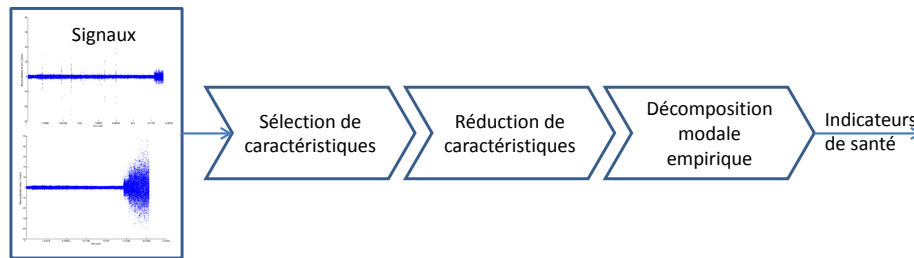


FIGURE 2.24: Construction d'indicateurs de santé par sélection - réduction - EMD.

- Signaux : données de surveillance fournies par les capteurs. Ils peuvent être de différents types : vibration, température, humidité, courant, tension, etc.
- Sélection de caractéristiques : pour chaque historique de données, on applique l'algorithme de sélection de caractéristiques basé sur l'information mutuelle développé dans la thèse d'A. Mosallam [100] et présenté dans la section 4. Dans cet algorithme, les caractéristiques qui reviennent fréquemment (plus de 50% du temps) sont sélectionnées et retenues pour la suite du traitement.
- Réduction de caractéristiques : les caractéristiques retenues sont réduites en une seule composante en utilisant l'ACP. La composante extraite correspond alors à l'intervalle de temps $[0, t]$, t étant l'instant courant. Ce processus est répété tout au long de la durée de vie des composants critiques pour générer des signaux de durées égales aux durées des historiques de données correspondants.
- Décomposition modale empirique : pour chaque signal obtenu à l'instant t par l'ACP, on extrait son résidu en utilisant l'EMD. Cette étape est répétée sur chacun des composants critiques. Pour rappel, l'EMD permet de séparer les différentes composantes d'un signal. En plus des IMFs du signal d'origine, l'EMD génère un résidu qui prend une allure quasi constante pour un composant critique en bon état de fonctionnement et une allure variable pour un composant critique en dégradation. Le résidu présentant une allure variable et monotone (croissante ou décroissante) est alors considéré comme indicateur de santé.

Les figures 2.25 et 2.26 montrent des exemples d'indicateurs de santé obtenus sur des données de roulements.

5.2 Indicateurs de santé générés en utilisant la transformée de Hilbert-Huang

Les indicateurs obtenus par l'EMD sont purement temporels et l'information fréquentielle n'y est pas explicitement représentée. Par conséquent, dans certaines applications tels que les roulements ou les engrenages, ces indicateurs sont moins efficaces pour révéler la dégradation et la suivre dans le temps. Pour y remédier, nous avons proposé dans le cadre des travaux du post-doctorant A. Soualhi [134] d'utiliser comme indicateurs les densités spectrales de Hilbert. Les indicateurs obtenus par cette méthode permettent de réaliser une analyse spectrale locale sur les IMFs issues de l'EMD. Ils ont ainsi un triple intérêt : ils permettent 1) de détecter l'instant pendant lequel la dégradation s'est produite en comparant la fréquence instantanée à la signature du défaut, 2)




FIGURE 2.25: Indicateurs de santé obtenus sur des données de la plateforme Pronostia.




FIGURE 2.26: Indicateurs de santé obtenus sur des données de la NASA [143].

de localiser l'élément responsable de la dégradation et 3) de suivre l'évolution de la dégradation en suivant la variation de la densité spectrale de Hilbert de chaque fréquence caractéristique. Les étapes de cette démarche sont résumées sur la figure 2.27 et brièvement décrites ci-dessous.

- Signal brut : image prise à l'instant t de l'historique de données (un fichier de l'historique de données).
- EMD : elle est appliquée sur le signal brut pour obtenir plusieurs IMFs, chacune d'une durée égale à la durée du signal brut.
- Transformée de Hilbert : elle est appliquée sur chaque IMF extraite précédemment, avec a_i l'amplitude instantanée.
- Densité spectrale de Hilbert : calculée pour chaque IMF.
- Sélection des IMFs : les IMFs retenues sont celles qui maximisent la densité spectrale de Hilbert autour des fréquences caractéristiques des défauts. Pour chaque fréquence caractéristique, on regarde parmi toutes les IMFs celle qui maximise la densité spectrale de Hilbert sur cette fréquence et on la garde. On obtient ainsi une seule IMF pour une fréquence donnée. Cela permet d'avoir au minimum une IMF (la même pour toutes les fréquences caractéristiques) et au maximum trois IMFs différentes (une pour chaque fréquence). La valeur de chaque IMF retenue est prise comme valeur de l'indicateur de santé, ce qui conduit au total à trois indicateurs (un par fréquence caractéristique).

La figure 2.28 illustre par un exemple le principe de sélection de l'IMF d'intérêt en fonction de la valeur maximale de la densité spectrale de Hilbert. Sur cette figure, l'IMF numéro 6 est retenue car elle maximise la densité spectrale de Hilbert autour de la fréquence caractéristique. La figure 2.29 montre trois indicateurs, un par fréquence caractéristique.

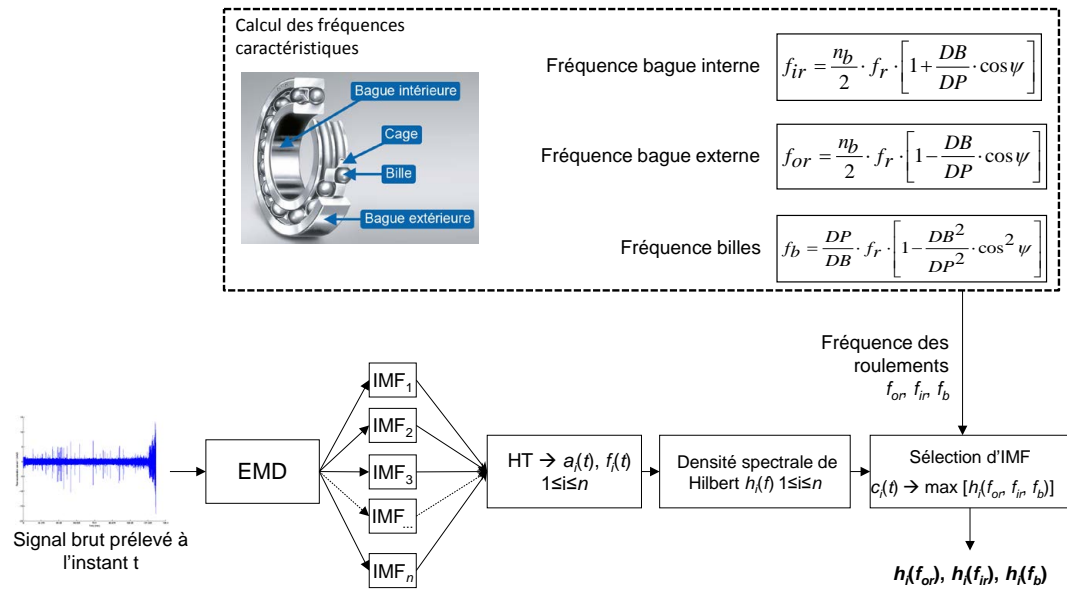


FIGURE 2.27: Démarche de construction d'indicateurs de santé en utilisant la transformée de Hilbert-Huang.

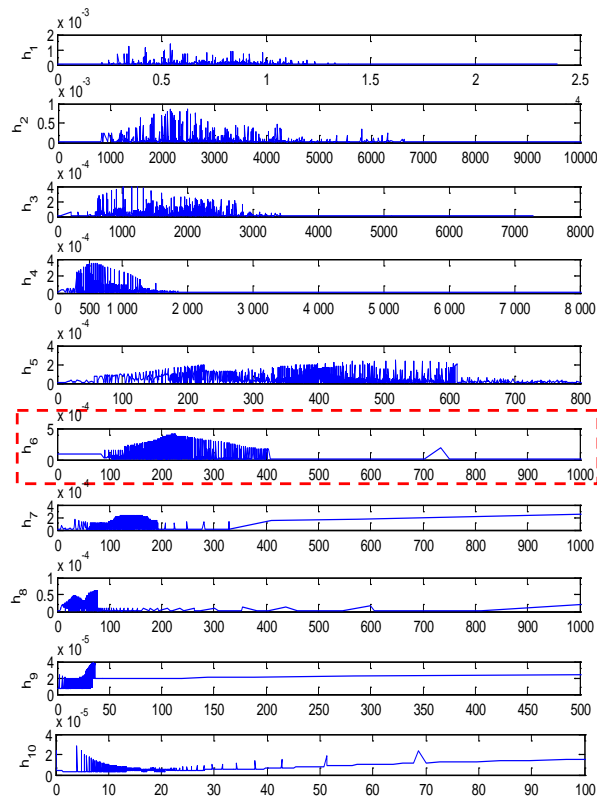


FIGURE 2.28: Illustration de la sélection des IMFs.

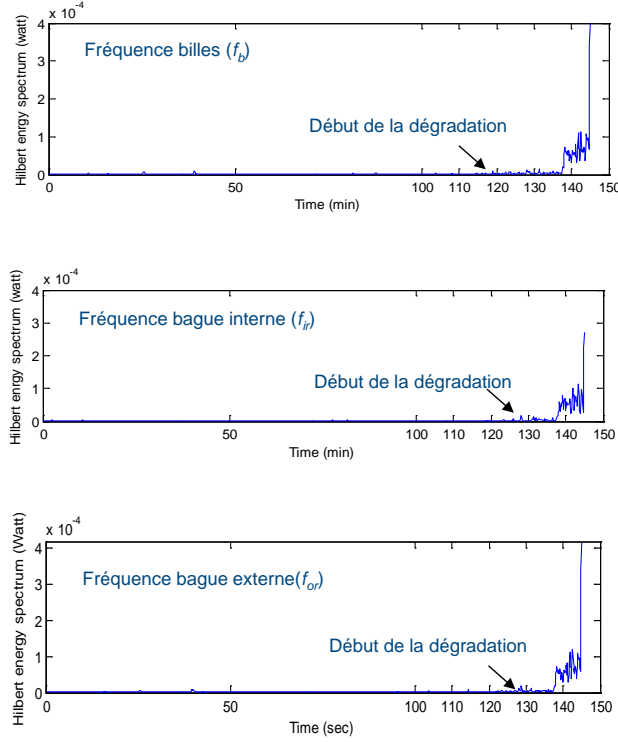


FIGURE 2.29: Indicateurs de santé obtenus en utilisant la transformée de Hilbert-Huang.

6 Conclusion

Dans ce chapitre, nous avons abordé la problématique globale du traitement des données de surveillance pour extraire des caractéristiques pertinentes et construire des indicateurs permettant de suivre l'état de santé de composants critiques. L'objectif est de transformer les signaux bruts fournis par les capteurs en signaux utiles permettant ultérieurement de détecter le déclenchement d'une dégradation, de diagnostiquer sa cause, de prédire sa progression et de prendre des décisions en conséquence. La solution à cette problématique a été réalisée en quatre étapes : l'extraction de caractéristiques, la réduction de caractéristiques, la sélection de caractéristiques et la construction d'indicateurs de santé.

Concernant l'extraction de caractéristiques, nous avons fait appel à différentes méthodes pour générer des caractéristiques dans les domaines temporel, fréquentiel et temps-fréquence sur des signaux stationnaires et non stationnaires. Les caractéristiques temporelles sont les plus faciles à obtenir et à mettre en œuvre. Elles sont efficaces en détection de défaillances, mais moins en diagnostic et en pronostic. En effet, en diagnostic elles ne permettent pas de remonter à la cause de la défaillance et, en pronostic, leur progression ne laisse pas suffisamment de temps pour anticiper la défaillance. Les caractéristiques fréquentielles permettent d'extraire des signatures utilisables en diagnostic de défauts des systèmes impliquant notamment les roulements et les engrenages. Cependant, elles ne permettent pas d'identifier avec précision le moment pendant lequel a eu lieu le défaut ou la défaillance. Elles sont également plus gourmandes en temps de calcul que les caractéristiques temporelles. Concernant les caractéristiques temps-fréquence, elles offrent une vision tridimensionnelle du signal (amplitude - temps - fréquence). Elles peuvent ainsi être utilisées en détection, en diagnostic et en pronostic de défaillances. La méthode la plus prometteuse dans ce domaine est sans doute la transformée de Hilbert-Huang. Elle repose sur

la transformée de Hilbert appliquée sur les IMFs extraites du signal d'origine où chaque IMF représente un mode oscillatoire particulier. On obtient ainsi des amplitudes instantanées et des fréquences instantanées pour chaque mode oscillatoire du signal d'origine, ce qui permet d'avoir un niveau d'analyse très fin.

Dans la pratique, les caractéristiques extraites peuvent être nombreuses, ce qui rend leur représentation, visualisation et analyse difficiles. Pour résoudre cette problématique, nous avons proposé d'utiliser des méthodes linéaires et non linéaires de réduction de caractéristiques. La méthode de réduction linéaire la plus répandue est l'ACP. Cependant, elle n'est pas toujours adaptée, car les caractéristiques extraites sont souvent non linéaires. Pour y remédier, nous avons proposé d'utiliser l'ACP à noyau ou mieux encore l'Isomap. Cette dernière vise à projeter les données initiales, qui sont difficiles à réduire linéairement dans leur espace de représentation d'origine, dans un espace de représentation de dimension plus élevée dans lequel la réduction linéaire des données projetées devient possible. La réduction linéaire réalisée dans le nouvel espace est alors équivalente à une réduction non linéaire dans l'espace d'origine. C'est donc une méthode adaptée à la nature des caractéristiques extraites dans la majeure partie des applications.

La sélection de caractéristiques vise à choisir un sous-ensemble de caractéristiques parmi celles initialement extraites. Elle permet de ne garder que les caractéristiques pertinentes en fonction de la tâche à réaliser. En effet, les caractéristiques utilisées dans la détection peuvent être différentes de celles employées en diagnostic ou encore en pronostic de défaillances. La sélection permet également de réduire les temps de calcul et d'inférence et d'améliorer l'applicabilité des algorithmes de PHM développés. Dans ce contexte, nous avons proposé une méthode de sélection supervisée basée sur une mesure d'incertitude symétrique et applicable sur des signaux capteurs ainsi que sur des caractéristiques brutes.

Enfin, dans ce chapitre, nous avons abordé la problématique de construction d'indicateurs de santé. Ces derniers constituent un moyen de suivre et de rendre compte de l'état de santé des composants critiques. Ils peuvent être obtenus à partir des signaux fournis par les capteurs ou à partir d'un ensemble de caractéristiques après un processus comportant des étapes de sélection et/ou de réduction. Dans ce cadre, nous avons fait appel à deux méthodes, il s'agit de l'EMD et de la HHT. L'EMD vise à décomposer le signal d'origine en plusieurs signaux plus un résidu. Ce dernier présente une allure constante pour un composant sain et une allure monotone croissante ou décroissante pour un composant en dégradation. Quant à la HHT, elle offre un niveau d'analyse temps-fréquence très fin et permet d'extraire des indicateurs pertinents utilisables en détection, diagnostic et pronostic de défaillances.

Dans la pratique, l'une des difficultés majeures du traitement des données est liée à l'identification des caractéristiques et des indicateurs de santé à générer à partir des signaux disponibles pour représenter le mécanisme de dégradation du composant.

Les caractéristiques et les indicateurs obtenus dans ce chapitre sont, pour la plupart, corrélés avec la dégradation mais sans causalité physique avec cette dernière. Cela signifie qu'il existe un lien entre la progression de la dégradation et la variation des caractéristiques et des indicateurs de santé, mais cela ne permet pas de la quantifier (comme par exemple déterminer la taille d'une fissure, la direction de sa propagation, le seuil limite accepté, etc.). En résumé, il n'est pas toujours aisé de déduire une interprétation physique des caractéristiques ou des indicateurs construits. Ce lien physique entre d'un côté les caractéristiques et les indicateurs de santé et de l'autre côté le comportement de la dégradation constitue un verrou majeur qu'il faudra lever dans nos futurs travaux.

Les caractéristiques extraites et les indicateurs de santé construits dans ce chapitre seront utilisés dans le chapitre suivant pour modéliser la dégradation du composant critique.

Chapitre 3

Modélisation de la dégradation

1 Introduction

Ce chapitre est consacré à la modélisation de la dégradation du composant critique. Il présente la démarche proposée et les outils utilisés dans nos travaux de recherche. L'objectif étant de transformer les caractéristiques extraites et les indicateurs de santé construits dans le chapitre précédent en modèles capables de renseigner sur le déclenchement et l'évolution de la dégradation (figure 3.1).

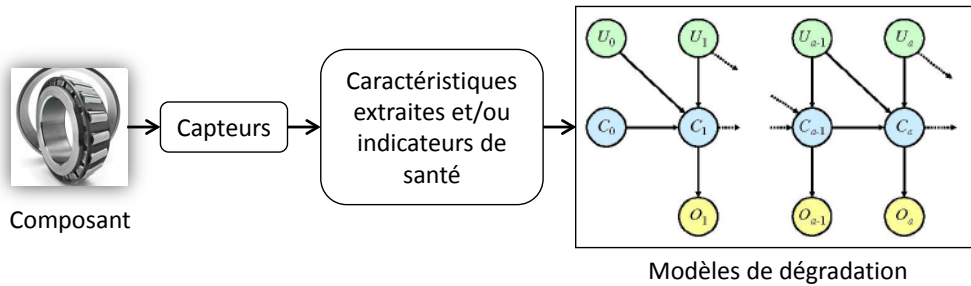


FIGURE 3.1: Transformation des données de surveillance en modèles.

Pour modéliser la dégradation du composant critique, nous avons besoin d'outils adéquats. Le choix de ces derniers est conditionné par un certain nombre de critères parmi lesquels le type de données à modéliser (mono-dimensionnelles, multi-dimensionnelles, continues, discrètes, déterministes, incertaines, etc.), la nature du phénomène de dégradation mis en jeu (déterministe, probabiliste, stochastique, linéaire, stationnaire, etc.) et les conditions de sollicitation ou de fonctionnement considérées.

Dans le cas de l'approche de pronostic guidée par les données, nous avons recensé différents outils de modélisation proposés dans la littérature scientifique. Les plus répandus sont les réseaux de neurones, les filtres de Kalman, le filtre particulaire, l'analyse de tendance et les régressions, les chaînes de Markov cachées, les processus stochastiques et les modèles de fiabilité [44, 56, 74, 131, 150].

Dans nos travaux, nous avons choisi d'utiliser trois catégories d'outils : les réseaux Bayésiens dynamiques [91, 148, 150], les modèles de régression non linéaires notamment les machines à vecteurs de support pour la régression (Support Vector Machines : SVRs) [16, 17, 134] et les processus de Gauss pour la régression (Gaussian Process Regression : GPR) [99]. Ce choix est

justifié par le fait que d'un côté, les RBDs généralisent les chaînes de Markov cachées et les filtres de Kalman [105] et que de l'autre côté, les SVRs et les GPRs offrent plus de possibilités que les régressions classiques pour la modélisation de l'incertitude et des non linéarités des données. Pour modéliser la dégradation, nous avons fait appel à deux catégories de données (cf. figure 3.2) : 1) matrice de caractéristiques pour les RBDs (travaux réalisés dans le cadre de la thèse CIFRE de D. A. Tobon-Mejia) et 2) séries temporelles (indicateurs de santé) pour les régressions (travaux de la thèse d'A. Mosallam et du post-doctorant A. Soualhi).




FIGURE 3.2: Données d'entrée des outils de modélisation utilisés.

Les outils de modélisation choisis ont été utilisés dans une démarche intégrée dont le principe est résumé sur le schéma de la figure 3.3. Cette démarche repose sur deux phases : une première phase d'apprentissage des modèles à partir d'historiques complets de données issues généralement de tests de vieillissement accéléré et une seconde phase d'utilisation des modèles appris. Ces derniers seront exploités pour estimer l'état courant du composant et prédire sa durée de fonctionnement avant défaillance (partie abordée dans le chapitre suivant). La démarche proposée repose également sur un ensemble d'hypothèses résumées ci-dessous.

1. Les données d'entrées (caractéristiques ou indicateurs de santé) sont continues et à valeurs réelles.
2. Les caractéristiques et les indicateurs de santé utilisés dans la phase d'apprentissage sont extraits à partir de données représentatives de cycles complets de dégradation (allant de l'état neuf du composant à son état défaillant en passant par différents états de dégradation).
3. Les caractéristiques et les indicateurs de santé sont supposés représenter l'évolution dans le temps de la dégradation du composant critique.
4. La dégradation subie par le composant est supposée progressive et irréversible. Les défaillances soudaines et les interventions préventives de maintenance ne sont pas considérées.

Dans la suite de ce chapitre nous présenterons chaque outil et expliquerons comment nous l'avons utilisé pour la modélisation de la dégradation.

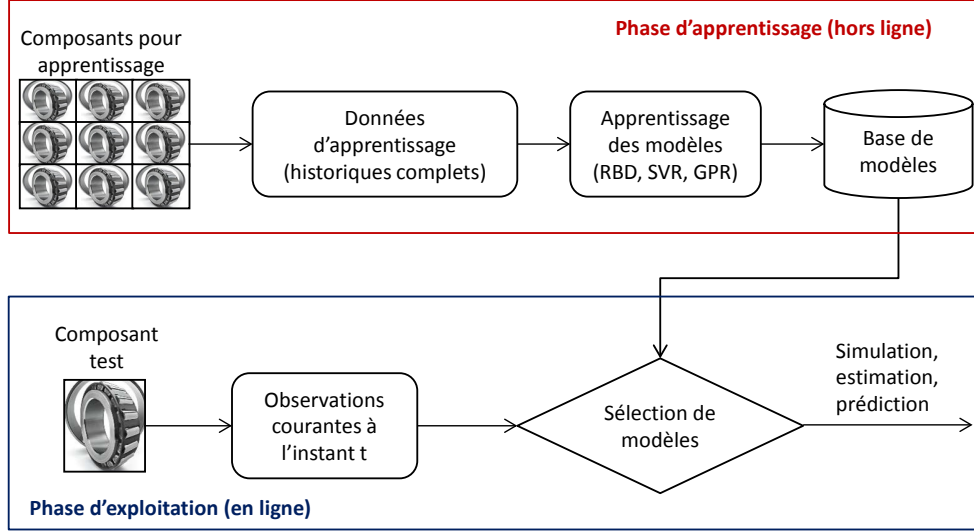


FIGURE 3.3: Phases de la démarche de modélisation.

2 Réseaux Bayésiens dynamiques

Pour transformer les matrices de caractéristiques extraites des signaux bruts en modèles, nous avons proposé d'utiliser les chaînes de Markov cachées à mélanges de Gaussiennes (Mixture of Gaussians Hidden Markov Models : MoG-HMMs) représentées par des réseaux Bayésiens dynamiques. Les MoG-HMMs sont des chaînes de Markov cachées (Hidden Markov Models : HMMs) dans lesquelles les observations ne sont pas discrètes mais continues et représentées par des mélanges de Gaussiennes. Ainsi, avant de les présenter, nous avons jugé judicieux de présenter les chaînes de Markov cachées discrètes.

2.1 Chaînes de Markov cachées

Une chaîne de Markov cachée à temps discret est un cas particulier d'un processus de Markov. Elle sert à modéliser des processus stochastiques et des variables aléatoires dépendantes. En général, un processus stochastique $X(t)$ est considéré comme un processus de Markov si pour tout sous ensemble fini d'instants $\{t_i, i = 1, 2, \dots, L\}$ tel que $t_1 < t_2 < \dots < t_L$, la distribution de probabilité conditionnelle de la variable aléatoire $X(t_L)$ connaissant $x(t_1), x(t_2), \dots, x(t_L)$ dépend seulement de la valeur précédente de la variable aléatoire :

$$\begin{aligned} P[X(t_L) = x_L | X(t_1) = x_1, \dots, X(t_{L-1}) = x_{L-1}] \\ = P[X(t_L) = x_L | X(t_{L-1}) = x_{L-1}] \end{aligned} \quad (3.1)$$

Cela signifie que connaissant le présent du processus, le futur est indépendant du passé. Cette propriété est connue sous le nom de propriété de Markov. Suivant la nature de l'espace d'états S , où $X(t) \in S$, et de l'espace de temps sur lequel est défini le paramètre t , les processus de Markov sont divisés en quatre classes (cf. figure 3.4) [132].

Dans la suite de cette description, nous nous intéresserons aux chaînes de Markov à temps discret. Dans ce cas, on considère que le composant modélisé ne peut se trouver que dans un seul état de l'ensemble S à chaque instant t . La probabilité que le composant soit à instant discret ($X_n = X(t_n)$) dans un état $x_i \in S$ est donnée par :

$$P_i(t) = P[X_t = x_i] \quad \forall x_i \in S \quad (3.2)$$

Nature du paramètre « t »	Espace d'états	
	Discret	Continu
Discret	Chaîne de Markov à temps discret	Processus de Markov à temps discret
Continu	Chaîne de Markov à temps continu	Processus de Markov à temps continu

FIGURE 3.4: Classification des processus de Markov [132].

La propriété de Markov est donc vérifiée par la probabilité conditionnelle suivante :

$$P[X_t = x_i | X_{t-1} = x_j, X_{t-2} = x_k \dots] = P[X_t = x_i | X_{t-1} = x_j], \forall x_i, x_j, x_k \in S \quad (3.3)$$

Cette distribution de probabilité conditionnelle est considérée indépendante du temps. Elle est aussi connue comme probabilité de transition entre états et définie dans l'intervalle $[0, 1]$, avec la contrainte stochastique $\sum_{j=1}^{\text{rang}(S)} a_{ij} = 1$. On a ainsi :

$$a_{ij} = P[X_t = x_i | X_{t-1} = x_j], 1 \leq i, j \leq \text{rang}(S) \quad (3.4)$$

Ce processus stochastique est aussi désigné sous le nom de chaîne de Markov observable, car ici les états sont directement accessibles. Ces états représentent des phénomènes ou événements physiques visibles. La figure 3.5 montre un composant dont l'état est représenté par une chaîne de Markov à trois états ($S = 3$). Dans cet exemple les états peuvent correspondre au composant en bon fonctionnement (Etat 1), défectueux (Etat 2) et en maintenance (Etat 3). La matrice de transition entre états, notée A , peut être obtenue à partir des données collectées durant son utilisation.

$$A = \begin{pmatrix} 0,85 & 0,1 & 0,05 \\ 0 & 0,05 & 0,95 \\ 0,8 & 0,1 & 0,1 \end{pmatrix}$$

Le modèle de la figure 3.5 peut être exploité pour estimer par exemple la probabilité de bon




FIGURE 3.5: Exemple d'une chaîne de Markov discrète.

fonctionnement du composant pendant une semaine de travail sachant qu'il est, au moment du calcul, en maintenance (on considérera qu'un pas de temps est égal à un jour). Formellement, cela peut être défini comme la probabilité de réaliser la séquence d'observations O où $O = \{\text{Etat3}, \text{Etat1}, \text{Etat1}, \text{Etat1}, \text{Etat1}, \text{Etat1}\}$ (ce qui correspond à l'état initial (maintenance) et les cinq jours de la semaine en bon fonctionnement). À partir de ces données, il est possible d'estimer

cette probabilité en utilisant l'expression suivante :

$$\begin{aligned}
P [O | \text{Modèle}] &= P [\text{Etat 3}, \text{Etat 1}, \text{Etat 1}, \text{Etat 1}, \text{Etat 1}, \text{Etat 1} | \text{Modèle}] \\
&= P [\text{Etat 3}] \times P [\text{Etat 1} | \text{Etat 3}] \times P [\text{Etat 1} | \text{Etat 1}] \times P [\text{Etat 1} | \text{Etat 1}] \\
&\quad \times P [\text{Etat 1} | \text{Etat 1}] \times P [\text{Etat 1} | \text{Etat 1}] \\
&= \pi_3 \times a_{31} \times a_{11} \times a_{11} \times a_{11} \times a_{11} \\
&= 1 \times 0,1 \times 0,85 \times 0,85 \times 0,85 \times 0,85 \\
&= 0,34
\end{aligned}$$

Dans cette expression, π_3 désigne la distribution de probabilité initiale.

Dans la pratique, les phénomènes représentés par les états d'une chaîne de Markov ne sont pas directement observables. Pour les modéliser on utilise des chaînes de Markov cachées (HMMs) [123] (figure 3.6).




FIGURE 3.6: Chaîne de Markov cachée (HMM).

Un HMM est complètement défini par les paramètres suivants [123] :

- N : nombre d'états. Les états individuels forment un ensemble noté S avec $S = \{x_1, x_2, \dots, x_N\}$ et l'état à un instant t discret est noté x_t .
- K : nombre d'observations différentes pour chaque état. Celles-ci sont les sorties mesurables du composant modélisé (exemple : température élevée, normale ou basse). Les observations forment un ensemble noté V , avec $V = \{v_1, v_2, \dots, v_K\}$.
- A : distribution de probabilité de transition entre les états cachés, $A = \{a_{ij}\}$, où

$$A = \{a_{ij}\} = P[x_t = i | x_{t-1} = j], 1 \leq i, j \leq N. \quad (3.5)$$

- B : distribution de probabilité des observations conditionnées par chaque état caché x_i , $B = \{b_i(k)\}$, où

$$B = b_i(k) = P[v_k | x_t = x_i], 1 \leq i \leq N \wedge 1 \leq k \leq K. \quad (3.6)$$

- π : distribution initiale des états $\pi = \{\pi_i\}$, avec

$$\pi_i = P[x_1 = x_i], 1 \leq i \leq N. \quad (3.7)$$

En connaissant les paramètres N , K , A , B , et π , on obtient un modèle du composant permettant de générer des séquences d'observations :

$$O = O_1 O_2 O_t \dots O_T, 1 \leq t \leq T$$

où chaque observation O_t est un élément de V et T représente la longueur de la séquence d'observations.

Dans la pratique, les paramètres N et K sont soit donnés par l'expert du composant, soit déterminés par expérience. Le modèle HMM est donc défini par ses trois paramètres A , B et π et est noté λ :

$$\lambda = (A, B, \pi) \quad (3.8)$$

Un modèle HMM est utilisé pour résoudre trois problèmes fondamentaux et couramment rencontrés dans les applications réelles [123] :

Problème 1 : appelé problème de reconnaissance ou de détection. Il correspond au calcul de la probabilité qu'une séquence d'observations $\{O = O_1 O_2 O_t \cdots O_T\}$ soit générée par un modèle $\lambda = (A, B, \pi)$, c.-à-d. $P[O|\lambda]$. Ce problème de reconnaissance peut être aussi considéré comme la capacité d'un modèle λ à bien représenter les observations du composant. En d'autres termes, si nous considérons le cas où nous devons choisir entre plusieurs modèles $\lambda_i = (A_i, B_i, \pi_i)$, la solution au problème de reconnaissance permet de sélectionner le modèle qui représente le mieux la séquence d'observations O . Pour résoudre ce problème il existe deux méthodes.

1. La première méthode est la plus directe mais aussi la plus gourmande en calculs, car elle consiste à considérer toutes les séquences d'états possibles Q de taille T , par exemple :

$$Q = x_1, x_2, \dots, x_T$$

Puis, elle évalue la probabilité des observations connaissant le modèle λ en faisant l'addition des probabilités jointes sur toutes les séquences d'états Q possibles [123].

$$\begin{aligned} P[O|\lambda] &= \sum_Q P[O|Q, \lambda] \times P[Q|\lambda] \\ &= \sum_{x_1, x_2, \dots, x_T} \pi_{x_1} b_{x_1}(O_1) a_{x_1 x_2} b_{x_2}(O_2) \cdots a_{x_{T-1} x_T} b_{x_T}(O_T) \end{aligned}$$

D'après l'expression ci-dessus, cette méthode demande $2 \times N^T$ opérations pour estimer la probabilité d'avoir la séquence d'observations connaissant le modèle [123]. Ce temps de calcul demande des ressources informatiques onéreuses rendant la mise en œuvre de la méthode difficile et ce même pour de petites dimensions de N et T . Par exemple, pour $N = 5$ états et $T = 100$ observations, il faut $2 \times 100 \times 5^{100} \approx 10^{72}$ opérations !

2. Une deuxième méthode plus performante, issue de la programmation récursive, a été proposée par Baum [14]. Cette solution est connue sous le nom d'algorithme « Forward - Backward ». Elle divise la séquence d'observations $\{O = O_1 O_2 O_t \cdots O_T\}$ en deux sous-séquences. La méthode s'appuie sur ces deux nouvelles séquences pour définir deux probabilités d'observations : $\alpha_t(i)$ pour la probabilité « forward » et $\beta_t(i)$ pour la probabilité « backward » :

$$\alpha_t(i) = P[O_1 O_2 \cdots O_t, x_t = x_i | \lambda] \quad (3.9)$$

$$\beta_t(i) = P[O_{t+1} O_{t+2} \cdots O_T, x_t = x_i | \lambda] \quad (3.10)$$

Pour l'estimation de $P[O|\lambda]$, seul le calcul de la probabilité « forward » est nécessaire. La variable $\beta_t(i)$ est utilisée pour aider à résoudre les problèmes 2 et 3. En général, cet algorithme nécessite un ordre de $T \times N^2$ opérations. Pour l'exemple précédent, la solution est obtenue avec ≈ 3000 opérations au lieu de 10^{72} opérations.

Problème 2 : appelé problème de décodage ou d'identification des états cachés du composant. On cherche ici à découvrir la partie cachée du modèle, c'est-à-dire de trouver la séquence d'états cachés :

$$X = x_1, x_2, \dots, x_T$$

En d'autres termes, étant donnée une séquence d'observations $\{O = O_1 O_2 O_t \dots O_T\}$ et un modèle $\lambda = (A, B, \pi)$, on cherche à trouver la séquence d'états cachés correspondante. Contrairement au problème 1, pour lequel une solution exacte peut être trouvée avec $T \times N^2$ opérations, dans le cas du problème de décodage il existe plusieurs possibilités pour le résoudre. Cela est dû au fait que la solution à ce problème fait appel à un critère d'optimisation. Par exemple, pour certains algorithmes, la solution consiste à trouver la séquence d'états en maximisant les probabilités d'occurrence individuelles des états de la séquence à l'aide des variables $\alpha_t(i)$ et $\beta_t(i)$ [123].

Toutefois, la solution la plus répandue est obtenue par l'algorithme de Viterbi [159]. Ce dernier utilise une mesure de probabilité $\delta(i)$ pour mesurer l'alignement le plus probable entre la séquence d'états X et les observations O jusqu'à un instant t , avec la contrainte $X_t = x_i$:

$$\delta_t(i) = \max_{x_1, x_2, \dots, x_T} P[x_1 x_2 \dots x_t = x_i, O_1 O_2 \dots O_t | \lambda] \quad (3.11)$$

Pour déterminer la séquence d'états cachés, il est donc nécessaire de garder la trace de l'indice i qui maximise $\delta(i)$, et cela pour tout t et tout i .

Problème 3 : appelé problème d'apprentissage et a pour objectif d'estimer les paramètres du modèle (π, A, B) du composant critique de façon à maximiser la probabilité de la séquence d'observations O . Ce problème n'a pas de solution analytique générale. Néanmoins, il existe un algorithme itératif, dit de Baum-Welch [13], qui permet de choisir $\lambda = (A, B, \pi)$ de telle façon que la probabilité $P[O | \lambda]$ soit localement maximisée.

En utilisant les résultats de l'algorithme « Forward - Backward » et de l'optimisation itérative on obtient les expressions suivantes qui permettent d'estimer les paramètres du modèle λ .

$$\overline{\pi_i} = \frac{\alpha_1(i) \beta_1(i)}{P[O | \lambda]} \quad (3.12)$$

= nombre de passages de l'état x_i au temps $t = 1$

$$\overline{a_{ij}} = \frac{\sum_{t=1}^{T-1} \alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^{T-1} \alpha_t(i) \beta_t(i)} \quad (3.13)$$

= $\frac{\text{nombre de passages de l'état } x_i \text{ à l'état } x_j}{\text{nombre de passages provenant de l'état } x_i}$

$$\overline{b_{jk}} = \frac{\sum_{O_t=v_k} \alpha_t(j) \beta_t(j)}{\sum_{t=1}^{T-1} \alpha_t(j) \beta_t(j)} \quad (3.14)$$

= $\frac{\text{nombre de fois où le symbole } v_k \text{ est observé à l'état } x_j}{\text{nombre de passages à l'état } x_j}$

2.2 Chaînes de Markov cachées à mélange de Gaussiennes

Dans les HMMs présentés précédemment les observations sont discrètes. Cependant, dans la pratique les observations sont souvent continues [149, 151]. Pour les modéliser, il est toujours possible de les discrétiser en utilisant des techniques de partitionnement (clustering), mais la perte d'information peut être significative [123, 152]. Pour y remédier, nous avons choisi de faire appel à des densités de probabilité continues.

La représentation générale d'une densité de probabilité, pour laquelle une procédure de ré-estimation des paramètres a été définie, est le mélange fini de la forme :

$$b_j(O) = \sum_{m=1}^M c_{jm} \mathfrak{S}[O, \mu_{jm}, U_{jm}], \quad 1 \leq j \leq N \quad (3.15)$$

Dans cette expression, O est le vecteur d'observations continues modélisé, c_{jm} le poids du mélange m dans l'état x_j et \mathfrak{S} une densité elliptique symétrique ou log-concave [62] de moyenne μ et de covariance U_{jm} pour le mélange m dans l'état x_j . Généralement, une distribution Gaussienne est utilisée pour \mathfrak{S} . On appelle ainsi le modèle obtenu chaîne de Markov cachée à mélange de Gaussiennes (Mixture of Gaussians Hidden Markov Model : MoG-HMM).

La densité de probabilité \mathfrak{S} est utilisée pour approximer la forme de la densité de probabilité réelle des observations, ce qui permet d'appliquer les MoG-HMMs sur une large gamme de composants. D'après [62], les formules utilisées pour estimer le poids c_{jm} de chaque mélange m , la moyenne μ_{jm} et la covariance U_{jm} sont données par les équations ci-dessous.

$$\overline{c_{jm}} = \frac{\sum_{t=1}^T \gamma_t(j, m)}{\sum_{t=1}^T \sum_{m=1}^M \gamma_t(j, m)} \quad (3.16)$$

$$\overline{\mu_{jm}} = \frac{\sum_{t=1}^T \gamma_t(j, m) \cdot O_t}{\sum_{t=1}^T \gamma_t(j, m)} \quad (3.17)$$

$$\overline{U_{jm}} = \frac{\sum_{t=1}^T \gamma_t(j, m) \cdot (O_t - \mu_{jm})(O_t - \mu_{jm})'}{\sum_{t=1}^T \gamma_t(j, m)} \quad (3.18)$$

Où l'apostrophe dénote la transposée du vecteur et $\gamma_t(j, m)$ la probabilité d'être dans l'état x_j à l'instant t avec le mélange m pour l'observation O_t .

$$\gamma_t(j, m) = \frac{\frac{\alpha_t(i) \beta_t(i)}{\sum_{j=1}^N \alpha_t(j) \beta_t(j)}}{\left[\frac{c_{jm} \mathfrak{S}(O_t, \mu_{jm}, U_{jm})}{\sum_{m=1}^M c_{jm} \mathfrak{S}(O_t, \mu_{jm}, U_{jm})} \right]} \quad (3.19)$$

En utilisant les équations de Baum-Welch [13] et celles de Juang [62] on peut estimer les paramètres d'un MoG-HMM à partir d'observations continues. Ce modèle est défini par les mêmes variables $\lambda = (A, B, \pi)$ où désormais la matrice B est déterminée par les paramètres c_{jm} , μ_{jm} et U_{jm} .

2.3 Réseaux Bayésiens Dynamiques

Les réseaux Bayésiens dynamiques (RBDs) [105] généralisent les chaînes de Markov cachées (et leur variantes MoG-HMM, Hidden Semi-Markov Models : HSMM, etc.) ainsi que les filtres de Kalman. Comparés à ces derniers, les RBDs possèdent les avantages suivants.

1. Réduction du nombre d'opérations de calcul par l'utilisation de nouveaux algorithmes d'inférence plus performants [105]. Cela permet de réaliser un apprentissage du modèle de dégradation et une inférence plus rapide surtout pour des phénomènes complexes comportant plusieurs états et/ou des matrices d'observations consécutives.
2. Facilité de représentation de modèles complexes grâce à la modélisation en deux couches définissant les paramètres initiaux du modèle et l'aspect dynamique (stochastique).
3. Relâchement des hypothèses liées au modèle du bruit pour l'apprentissage et l'inférence dans le cadre des filtres de Kalman.

Les travaux de K. P. Murphy [105] sur la définition et la formalisation des RBDs offrent un cadre puissant de développement et d'utilisation de cet outil dans plusieurs domaines des sciences pour l'ingénieur.

Les RBDs sont une extension des réseaux bayésiens (RBs) introduits par Pearl [113]. Un RB est un formalisme qui unifie différents concepts de modélisation probabiliste utilisés en statistique. Il permet d'estimer la distribution de probabilité conditionnelle des différentes variables du modèle à partir d'un graphe acyclique dirigé (DAG) et une table de probabilité conditionnelle (TPC). Un RB peut ainsi être utilisé pour calculer la probabilité d'occurrence d'un événement en fonction d'autres événements ayant des relations causales avec lui.

Les RBDs ont été initialement introduits par Dean et Kanazawa [34] comme une généralisation des RBs où les variables sont considérées comme des processus stochastiques pouvant varier dans le temps (comme la dégradation, par exemple). Si on s'intéresse à une variable d'état X_t évoluant dans un temps $1 \leq t \leq T$, alors le RBD représente la distribution de probabilité sur cet intervalle temporel. Cette évolution peut être modélisée soit sous la forme d'un RB dit statique à T variables (figure 3.7-(a)) le rendant exploitable pour une durée de temps limitée T , soit par le formalisme compact d'un RBD (figure 3.7-(b)) pouvant déterminer la distribution de la variable d'état à tout instant T par l'exploitation des probabilités conditionnelles (propriété de Markov).




FIGURE 3.7: Représentation d'un processus stochastique de Markov par RB et RBD : (a) solution déroulée (RB) et (b) solution compacte, selon [103]

Selon K. P. Murphy [105], un RBD est défini par le couple (B_1, B_{\rightarrow}) , où B_1 est le RB qui définit la distribution de probabilité initiale des variables aléatoires $P[Z_1]$ (avec $Z_t = (X_t, O_t)$ pour le cas d'un HMM, par exemple) et B_{\rightarrow} est un réseau Bayésien temporel à deux couches représentant la relation entre les distributions de probabilité des variables entre deux instants temporels successifs $P[Z_t|Z_{t-1}]$ par le biais d'un DAG :

$$P[Z_t|Z_{t-1}] = \prod_{i=1}^N P[Z_t^i | \text{Pa}(Z_t^i)] \quad (3.20)$$

Dans l'équation (3.20) Z_t^i est la variable aléatoire i (X_t, O_t , par exemple) à l'instant t et $\text{Pa}(Z_t^i)$ sont ses parents (ou variables causales) dans le graphe (DAG). Les probabilités de transition entre deux instants $P[Z_t|Z_{t-1}]$ sont définies par des distributions de probabilité conditionnelles (DPC) qui sont invariantes dans le temps.

Dans un RBD, les parents d'un nœud $\text{Pa}(Z_t^i)$ peuvent être dans la même tranche temporelle et/ou dans la tranche précédente. Les arcs dans un RBD (entre deux tranches temporelles) représentent la causalité dite « instantanée ». Ces arcs vont de gauche à droite et représentent les flux causaux dans le temps. La différence principale entre un RBD et un HMM est que dans le premier l'état caché peut être représenté par un groupe de variables aléatoires $X_t^1, \dots, X_t^{N_h}$, tandis que pour un HMM l'espace d'états est décrit par une seule variable aléatoire X_t . Les RBDs permettent ainsi de gérer plus aisément des structures complexes où les variables ont des dépendances difficiles à représenter par des HMMs.

Un RBD est exploitable s'il respecte les conditions suivantes [103, 105] :

- le temps est représenté de manière discrète, $t = 1, 2, \dots, T$ (processus à temps discret) ;
- les nœuds peuvent être regroupés par instants temporels contenant n variables identiques : Z_t^1, \dots, Z_t^n (vision synchrone) ;
- les variables Z_t^n d'une tranche temporelle t dépendent seulement des variables de la même tranche t ou de variables de la tranche temporelle précédente $t - 1$ (propriété de Markov) ;
- les distributions de probabilité conditionnelles sont indépendantes du temps (hypothèse de stationnarité ou de processus homogène).

2.4 Représentation des HMMs et des MoG-HMMs par des RBDs

La figure 3.8 montre un HMM modélisé par un RBD. La convention concernant la représentation des RBDs recommande de mettre en gris les nœuds (variables) observés et de laisser en clair les variables cachées. Ce graphe satisfait la condition d'indépendance $X_{t+1} \perp X_{t-1} | X_t$ (propriété de Markov) et $O_t \perp O_{t'} | O_t$ pour $t' \neq t$.




FIGURE 3.8: Représentation d'un HMM par un RBD déroulé sur 3 instants.

Une fois les variables observables et cachées sont identifiées, l'étape suivante consiste à définir les probabilités conditionnelles pour chaque nœud. En l'occurrence, pour le HMM de la figure 3.8, il s'agit de préciser $P[X_1]$, $P[X_t|X_{t-1}]$ et $P[O_t|X_t]$. Selon le RBD de la figure 3.9 qui généralise un HMM, la DPC de $P[X_1]$ est représentée par un vecteur qui définit la distribution de probabilité initiale du modèle, c'est à dire $P[X_1 = i] = \pi(i)$, où $0 \leq \pi(i) \leq 1$ et $\sum_i \pi(i) = 1$. La DPC du nœud $P[X_t] = P[X_t = x_j | X_{t-1} = x_i]$ est représentée par une matrice de probabilité stochastique $A(i, j)$ où chaque colonne représente une probabilité conditionnelle de transition d'un état à un autre. Dans ce RBD, la DPC pour les observations $P[O_t = v_k | X_t = x_i]$ peut être aussi définie par une matrice stochastique de type $P[O_t = v_k | X_t = x_i] = B = \{b_i(k)\}$. Comme les paramètres d'un HMM sont supposés invariants dans le temps, ils peuvent être représentés avec seulement quatre nœuds et trois DPCs indépendamment du nombre d'états dans le modèle

(voir la figure 3.9-(b)). Un autre avantage de représenter un HMM par un RBD est de pouvoir modéliser facilement les autres variantes (MoG-HMM, HSMM, etc.) des HMMS.




FIGURE 3.9: Représentation d'un HMM par un RBD : (a) détails des nœuds et (b) version générale compacte où $P[X_1 = i] = \pi(i)$, $P[X_t] = P[X_t = x_j | X_{t-1} = x_i] = A(i, j)$, et $P[O_t = v_k | X_t = x_i] = B = \{b_i(k)\}$

Dans la pratique, les applications dans lesquelles les observations sont continues sont nombreuses. Dans ces cas, le modèle le plus adapté est le MoG-HMM. Ce dernier peut être facilement représenté par un RBD [105]. En effet, il est possible de définir $P[O_t = v_k | X_t = x_i]$ par le biais d'un mélange de Gaussiennes. La figure 3.10 montre un RBD généralisant ce cas. L'idée consiste à ajouter de nouveaux nœuds (C) caractérisant les poids du mélange c_{jm} et de spécifier la relation entre les différentes variables, c'est à dire le conditionnement des observations par rapport à l'état et aux mélanges. Cela donne lieu à la définition de nouvelles DPCs pour les nœuds O et C :

$$P[O_t | X_t = x_i, C_t = m] = \mathcal{N}(O_t, \mu_{im}, U_{im}) \quad (3.21)$$

$$P[C_t = m | X_t = x_i] = c_{im} \quad (3.22)$$




FIGURE 3.10: Représentation d'un MoG-HMM par un RBD : (a) modèle déroulé sur trois instants et (b) version générale compacte.

Une fois la représentation du MoG-HMM par un RBD est établie, nous disposons d'une palette d'algorithmes permettant de résoudre les trois problèmes types : détection, décodage et apprentissage. Concernant notre application, nous supposons que la structure graphique est connue (MoG-HMM de la figure 3.10-(b)). Dans ce cas, pour estimer les paramètres du MoG-HMM qui représente la dégradation du composant critique, nous faisons appel aux algorithmes existants [15, 103]. Ces derniers diffèrent selon que les données d'apprentissage et/ou la structure du

RBD sont complètement ou partiellement connues (cf. tableau 3.1). En ce qui nous concerne, l'algorithme le plus adapté est celui de maximisation de l'espérance (Expectation-Maximization : EM) [88,93] ou encore sa combinaison avec l'algorithme d'estimation du maximum de probabilité *a posteriori* (maximum *a posteriori* : MAP) [135].

		Structure	
		Connue	Inconnue
Données	Complètes	<ul style="list-style-type: none"> – Approche bayésienne – Maximum de vraisemblance – MAP (Maximum <i>a posteriori</i>) 	<ul style="list-style-type: none"> – Recherche d'un arbre optimum (MWST) – Algorithme K2 – Algorithme PC – Algorithme de recherche gloutonne (<i>GS</i>, <i>greedy search</i>)
	Incomplètes	<ul style="list-style-type: none"> – Algorithme EM (<i>Expectation-Maximisation</i>) – EM + MAP 	<ul style="list-style-type: none"> – Structural EM

TABLE 3.1: Algorithmes d'apprentissage des paramètres d'un RBD [15, 103].

Après l'estimation des paramètres du modèle, ce dernier peut être utilisé en ligne sur de nouvelles observations pour connaître l'état de santé du composant. Pour cela, il existe différents algorithmes selon que l'inférence est exacte ou approximée [105]. L'inférence dépend principalement du type de variables représentées par les nœuds cachés du modèle. Si toutes les variables cachées sont discrètes (cas des HMMs), des méthodes exactes peuvent être utilisées pour estimer les paramètres α et β et permettre ainsi d'apporter une solution aux problèmes de décodage et de détection. Dans le cas contraire, des méthodes approximées sont utilisées. Elles exploitent des techniques déterministes ou stochastiques pour calculer les probabilités $P[O|\lambda]$ et $P[X_t = x_i|O_t, \lambda]$. Le tableau 3.2 résume les algorithmes qui peuvent être utilisés dans chaque cas.

Inférence		
Exacte	Approximée	
	Déterministe	Stochastique
<ul style="list-style-type: none"> – Algorithme Forward - Backward – Algorithme de la frontière (<i>Frontier Algorithm</i> ou <i>FF</i>) – Algorithme d'interface (arbres de jonction) – Algorithme de l'île (<i>Island algorithm</i>) 	<ul style="list-style-type: none"> – Algorithme de Boyen - Koller – Algorithme de la frontière factorisé (<i>FF</i>) – Propagation bouclée de la croyance (<i>Loopy belief propagation</i> ou <i>LBP</i>) – Propagation de l'espérance 	<ul style="list-style-type: none"> – Filtre particulaire – Filtre particulaire de type Rao - Blackwell

TABLE 3.2: Algorithmes d'inférence pour un RBD (voir [105] pour plus de détails).

La majeure partie des algorithmes d'apprentissage et d'inférence est implémentée sous forme d'une boîte à outils utilisable sous Matlab[®] [104].

La procédure à suivre pour modéliser la dégradation du composant critique et prédire sa progression dans le temps est résumée ci-dessous. Cette procédure a été mise en place dans le cadre de la thèse de D. A. Tobon-Mejia [146].

1. Définir les variables du MoG-HMM représenté par un RBD (nombre d'états discrets correspondant aux stades de dégradation, nombre d'observations correspondant aux caractéristiques utilisées et nombre de mélanges de Gaussiennes pour mieux représenter les observations).
2. Élaborer la structure du RBD (créer les arcs et les transitions entre les états, voir la figure 3.10-(b)).
3. Estimer les paramètres π , A et B du modèle RBD en utilisant les algorithmes existants (cf. tableau 3.1).
4. Exploiter en ligne le modèle obtenu en utilisant les algorithmes existants (cf. tableau 3.2).

2.5 Choix des paramètres des modèles MoG-HMMs et RBDs

L'utilisation des MoG-HMMs, représentés par des RBDs, nécessite la définition du nombre d'états S et du nombre de mélanges M . Le nombre d'états peut varier d'une application à une autre et peut être déterminé de deux manières différentes : soit donné par l'expert du système (ou du composant critique) étudié, soit appris à partir de l'analyse des données de surveillance disponibles. Dans le premier cas, l'expert peut suggérer le nombre d'états à utiliser en se basant sur sa connaissance du mécanisme de dégradation du composant critique ou sur le retour d'expérience dont il dispose. À titre d'exemple, dans le cas des roulements, l'expert peut proposer trois états qui correspondent aux états normal, dégradé et défaillant du roulement. Dans le second cas, le nombre d'états est déterminé après analyse des données utilisées pour l'apprentissage du modèle. La représentation de ces données dans un espace multidimensionnel peut révéler des partitions qui peuvent être assimilées aux états du composant. Toutefois, dans les deux cas, le nombre d'états ne doit pas être élevé pour avoir des temps d'apprentissage et d'inférence raisonnables.




FIGURE 3.11: Étude de sensibilité pour déterminer le nombre de mélanges M .

Concernant le nombre de mélanges, il est fixé à partir d'études de sensibilité telle que celle présentée sur la figure 3.11. Pour chaque historique de données on procède à l'apprentissage des paramètres du modèle pour différentes valeurs du nombre de mélanges M . Puis, une fois les paramètres sont estimés, on calcule la probabilité $P[O|\lambda_{\text{RBD}}]$ qui correspond à la vraisemblance du modèle. On choisit ainsi la valeur de M à partir de laquelle la vraisemblance commence à converger. Comme pour le nombre d'états, le nombre de mélanges ne doit pas être élevé pour que les phases d'apprentissage et d'inférence soit réalisables dans des temps raisonnables.

3 Séparateurs à vaste marge pour régression

Un SVR (Support Vector Regression) est un séparateur à vaste marge (Support Vector Machine : SVM) utilisé pour la régression de séries temporelles. Les SVRs sont utilisés dans nos travaux pour modéliser les indicateurs de santé construits à partir de données liées au dégradation du composant critique. Avant de présenter les SVRs, nous avons jugé judicieux d'introduire les SVMs.

3.1 Séparateurs à vaste marge

Les séparateurs à vaste marge, appelés également machines à vecteurs de support, sont des techniques d'apprentissage supervisées utilisées pour la classification (affectation d'une observation à une classe), la régression (prédiction de la valeur numérique d'une observation) et la détection de formes [156]. ils peuvent donc être utilisés pour détecter à tout instant l'état courant du composant critique. Ils sont une généralisation des classifieurs linéaires et reposent sur deux idées principales : la marge maximale et la fonction noyau. La marge correspond à la plus petite distance entre la frontière de séparation (appelée hyperplan séparateur) et les points les plus proches (appelés vecteurs supports). La fonction noyau permet, dans le cas où les données ne sont pas séparables linéairement, de transformer l'espace de représentation (ensemble des données) en un espace de dimension plus élevée dans lequel il est possible de les séparer linéairement. Les SVMs peuvent être utilisés comme classifieurs bi-classes ou multi-classes sur des données pouvant être séparables ou non séparables [19]. Dans la suite de cette introduction, et dans un souci de clarté, seul le cas bi-classe sur des données non séparables est présenté.

Avant de procéder à la classification par un SVM, on transforme l'ensemble des indicateurs de santé du composant critique en une matrice de données composée de M colonnes (représentant M indicateurs) et N lignes (représentant N observations). Les données contenues dans cette matrice, dans laquelle la variable temps n'apparaît pas, peuvent être représentées dans un espace multidimensionnel (cf. figure 3.12).

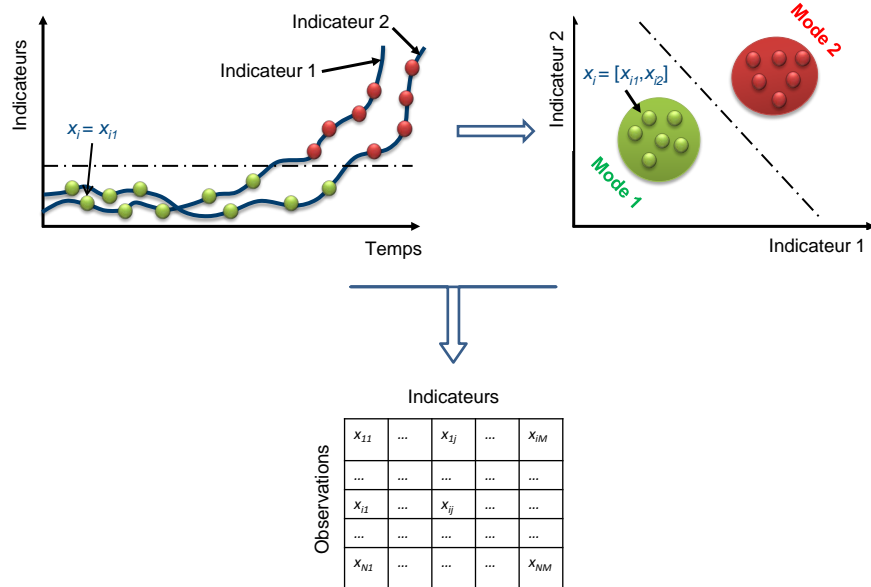


FIGURE 3.12: Représentation multi-dimensionnelle et matricielle des indicateurs de santé.

Le but du SVM est de trouver une fonction de classification $y(x)$ à partir de données d'apprentissage (figure 3.13). Cette fonction est ensuite utilisée pour classer de nouvelles données.




FIGURE 3.13: Principe de classification par SVM.

Pour séparer les données, on doit accepter que certaines d'entre elles soient mal classées (se retrouver du mauvais côté des frontières de la marge) en leur attribuant une pénalité qui augmente en fonction de leur éloignement des deux frontières de la marge. On parle ainsi de marge souple (figure 3.14). Pour cela, on introduit des variables ressort (appelées slack variables dans la communauté SVM) $\xi_n \geq 0$ avec $n = 1, \dots, N$. On a ainsi une variable ressort pour chaque donnée d'apprentissage, avec $\xi_n = 0$ pour les données qui sont du bon côté ou sur la frontière de la marge (données bien classées) et $\xi_n = |l_n - y(x_n)|$ pour les autres données ; $l \in \{-1, +1\}$ étant le label correspondant à chaque donnée. Les données qui se trouvent sur l'hyperplan séparateur ($y(x_n) = 0$) vont avoir $\xi_n = 1$ et celles qui sont mal classées vont avoir $\xi_n > 1$.

Pour résoudre le problème de classification, on cherche un hyperplan séparateur dans l'espace de représentation $\phi(x)$ et maximisant la marge. Cet hyperplan est donné sous forme d'une fonction linéaire $y(x)$:

$$y(x) = w^T \phi(x) + b \quad (3.23)$$

où w et b sont deux paramètres inconnus à estimer à partir des données d'apprentissage et $\phi(x)$ une fonction de transformation (cf. section 3.2 du chapitre 2) permettant de passer de l'espace de représentation d'origine vers un espace de dimension plus grande dans lequel il est possible de séparer linéairement les données transformées.




FIGURE 3.14: Principe du séparateur à marge souple.

Pour trouver les paramètres w et b , on utilise une base de données d'apprentissage composée de N vecteurs x_1, \dots, x_N avec des classes labellisées correspondantes l_1, \dots, l_N , $l \in \{-1, +1\}$. On cherche alors à maximiser la marge souple tout en pénalisant les données qui se trouvent du mauvais côté de l'hyperplan séparateur. Cela revient à minimiser la quantité suivante [19] :

$$\eta \sum_{n=1}^N \xi_n + \frac{1}{2} \|w\|^2 \quad (3.24)$$

sous les contraintes :

$$l_n y(x_n) \geq -1 + \xi_n, n = 1, \dots, N \quad (3.25)$$

$$\xi_n \geq 0 \quad (3.26)$$

où $\eta > 0$ est un paramètre de réglage qui assure un compromis entre l'erreur de classification et la complexité du modèle recherché.

La minimisation de la quantité donnée par l'équation (3.24) sous les contraintes (3.25) et (3.26) revient à résoudre un problème d'optimisation quadratique pour obtenir les paramètres w et b (voir [19] pour plus de détails). La résolution de ce problème conduit à l'équation de l'hyperplan séparateur qui permet de classer de nouvelles données (valeurs des indicateurs de santé) :

$$y(x) = \sum_{n=1}^N a_n l_n k(x, x_n) + b \quad (3.27)$$

Dans l'équation (3.27) $k(x, x_n)$ représente la fonction noyau (cf. section 3.2 du chapitre 2) permettant de s'affranchir de la définition de la fonction de transformation ϕ (passage dans un espace de dimension plus grande que la dimension des données d'origine). Le paramètre b est obtenu par une moyenne sur tous les vecteurs supports :

$$b = \frac{1}{N_{VS}} \sum_{n \in VS} \left(l_n - \sum_{m \in VS} a_m l_m k(x_n, x_m) \right) \quad (3.28)$$

où VS représente le nombre de vecteurs supports (points se trouvant sur la marge ou à l'intérieur de la marge). Dans le modèle (3.27), seuls les vecteurs supports interviennent dans le calcul de la fonction de classification (hyperplan). Les nouvelles observations collectées en ligne peuvent être affectées à l'une des deux classes en fonction du signe obtenu après évaluation de la fonction $y(x)$. Les SVMs peuvent ainsi être utilisés pour estimer l'état de santé courant du composant critique concerné.

3.2 Séparateurs à vaste marge pour régression

Lorsque les SVMs sont utilisés pour la régression, ils sont appelés SVRs. Dans ce cas, la sortie du modèle n'est plus l'appartenance à une classe, mais une valeur réelle (figure 3.15). Les SVRs sont utilisés dans nos travaux sur des indicateurs de santé afin de modéliser la dégradation du composant critique.



FIGURE 3.15: Principe simplifié du SVR.

Un SVR est une régression clairsemée (sparse regression) dont l'erreur quadratique de prédiction est légèrement différente de celle d'une régression linéaire. Dans une régression linéaire l'erreur

quadratique est donnée par l'équation suivante :

$$\frac{1}{2} \sum_{n=1}^N \{\hat{y}_n - y_n\}^2 + \frac{\tau}{2} \|w\|^2 \quad (3.29)$$

où \hat{y}_n est la valeur estimée par le modèle de régression, y_n la valeur réelle, w le vecteur des paramètres de la régression et τ un coefficient de régularisation ajouté pour empêcher le sur-ajustement (overfitting). Dans le cas du SVR, l'erreur quadratique est remplacée par ce qu'on appelle erreur ϵ -insensible [19, 156]. Cette erreur est égale à zéro si la valeur absolue de la différence entre la valeur estimée et la valeur réelle est inférieure à ϵ , avec $\epsilon > 0$. Un exemple d'erreur ϵ -insensible linéaire en dehors de la région ϵ -insensible est donnée par la relation suivante :

$$E_\epsilon(\hat{y}(x) - y) = \begin{cases} 0 & \text{si } |\hat{y}(x) - y| < \epsilon \\ |\hat{y}(x) - y| - \epsilon & \text{sinon} \end{cases} \quad (3.30)$$

Dans un SVR on est amené à minimiser une erreur exprimée par l'équation (3.31) dans laquelle le paramètre η est introduit pour contrôler le compromis entre la précision du modèle et sa complexité.

$$\eta \sum_{n=1}^N E_\epsilon(\hat{y}(x_n) - y_n) + \frac{1}{2} \|w\|^2 \quad (3.31)$$

Pour résoudre ce problème, on affecte à chaque point x_n de l'indicateur de santé deux variables ressorts $\xi \geq 0$ et $\hat{\xi} \geq 0$, où $\xi > 0$ correspond à un point pour lequel $y_n > \hat{y}(x_n) + \epsilon$ et $\hat{\xi} > 0$ correspond à un point pour lequel $y_n < \hat{y}(x_n) - \epsilon$ (figure 3.16)

La condition pour qu'un point y_n soit à l'intérieur du ϵ -tube est que $\hat{y}(x_n) - \epsilon \leq y_n \leq \hat{y}(x_n) + \epsilon$.




FIGURE 3.16: Principe du SVR.

Les échantillons qui sont à l'extérieur du tube vérifient les deux conditions suivantes :

$$y_n \leq \hat{y}(x_n) + \epsilon + \xi_n \quad (3.32)$$

$$y_n \geq \hat{y}(x_n) - \epsilon - \hat{\xi}_n \quad (3.33)$$

avec $\xi > 0$ et $\hat{\xi} > 0$.

L'erreur donnée par l'équation (3.31) peut alors être reformulée comme suit :

$$\eta \sum_{n=1}^N (\xi_n - \hat{\xi}_n) + \frac{1}{2} \|w\|^2 \quad (3.34)$$

Le modèle de régression peut être ainsi obtenu en minimisant l'erreur formulée par l'équation (3.34) et en tenant compte des contraintes $\xi \geq 0$, $\hat{\xi} \geq 0$ et de celles données par les expressions (3.32) et (3.33). Cela revient à résoudre un problème d'optimisation quadratique sous contraintes (voir [19] pour plus de détails). La résolution de ce problème conduit au modèle $\hat{y}(x_n)$ permettant d'estimer les valeurs de l'indicateur de santé en fonction de nouvelles observations.

$$\hat{y}(x_n) = \sum_{n=1}^N (a_n - \hat{a}_n) k(x, x_n) + b \quad (3.35)$$

Le paramètre b peut être obtenu en prenant un point quelconque pour lequel $0 < a_n < \eta$ et $\xi_n = 0$ et qui vérifie $\varepsilon + \hat{y}_n - y_n = 0$:

$$b = y_n - \varepsilon - \sum_{m=1}^N (a_m - \hat{a}_m) k(x_n, x_m) \quad (3.36)$$

Il est également possible d'utiliser un point pour lequel $0 < \hat{a}_n < \eta$.

Pour rappel, dans un SVR les vecteurs supports sont les points pour lesquels $a_n \neq 0$ ou $\hat{a}_n \neq 0$, c'est à dire, les points qui se trouvent sur les frontières du ϵ -tube ou à l'extérieur du tube. Ce sont les seuls points qui interviennent dans le modèle de régression (3.35). Les points qui sont à l'intérieur du tube n'interviennent pas dans l'estimation des sorties de nouvelles données d'entrée. Ce résultat est important lors de la mise en œuvre du modèle SVR obtenu puisqu'il permet de réduire le temps de calcul.

La procédure à suivre pour modéliser la dégradation du composant critique en utilisant les SVRs sur des indicateurs de santé est résumée ci-dessous. Cette procédure a été appliquée sur deux types de composants : la dégradation des roulements [134] et l'usure des outils de coupe [16, 17].

1. Construire l'indicateur de santé.
2. Définir les paramètres du SVR : η et $k(x, x_n)$.
3. Apprendre le modèle de régression $\hat{y}(x_n) = \sum_{n=1}^N (a_n - \hat{a}_n) k(x, x_n) + b$ à partir des indicateurs de santé disponibles.
4. Exploiter le modèle appris pour estimer en ligne l'état de santé du composant.

Le modèle de régression obtenu peut être également ajusté à un modèle analytique (de type polynômial, exponentiel, etc.) pour prédire l'état de santé du composant.

3.3 Choix du paramètre η

Le paramètre η , dont les valeurs sont strictement positives, est utilisé dans les SVRs pour assurer un compromis entre l'erreur d'apprentissage et la complexité du modèle. Une valeur importante de ce paramètre conduit à une diminution de l'erreur d'apprentissage, mais augmente la complexité du modèle de régression. Pour le définir, on peut réaliser plusieurs tentatives d'apprentissage/test en modifiant à chaque fois sa valeur, puis on estime et trace l'erreur d'apprentissage et la complexité (ordre du modèle de régression) en fonction des valeurs prises par η . Les tentatives d'apprentissage/test peuvent être réalisées avec la méthode de validation croisée (cross validation) [19].

4 kNN et GPR

Dans la thèse d’Ahmed Mosallam [100, 102], nous avons proposé une approche intégrée qui permet, à partir des indicateurs de santé construits des données de surveillance, d’estimer l’état courant du composant et de prédire son état futur. Cette approche repose sur la combinaison des k plus proches voisins (k Nearest Neighbors : kNN), du processus de Gauss pour la régression (Gaussian Process Regression : GPR) et du filtre Bayésien (figure 3.17). Dans la suite de cette section, seuls le kNN et le GPR seront présentés.

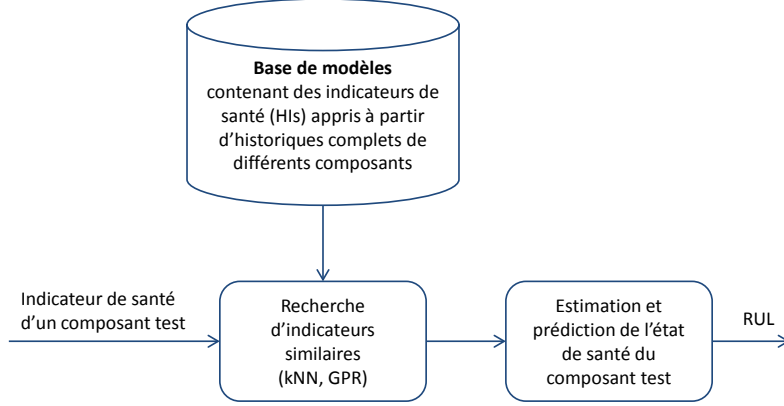


FIGURE 3.17: Intégration des outils kNN et GPR.

Le kNN est utilisé dans la phase test, réalisée en ligne, pour sélectionner l’indicateur de santé qui est le plus proche de l’indicateur de santé courant construit à l’instant t . Dans le cas où le résultat du kNN n’est pas satisfaisant (erreur de classification élevée) on fait appel au GPR.

4.1 kNN

Afin de sélectionner l’indicateur de santé le plus similaire aux observations courantes de la base des indicateurs de santé appris hors ligne, nous proposons d’utiliser le classifieur des k plus proches voisins [19]. Ce dernier est un algorithme d’apprentissage non paramétrique et sans modèle *a priori* sur la distribution des données [19]. Grâce à sa simplicité, le kNN est particulièrement adapté à une utilisation en ligne. La classification est basée sur la probabilité *a posteriori* des données test.

Dans la suite de cette description, on associe à chaque indicateur de santé construit à l’instant t une valeur notée EOL (End Of Life ou fin de vie du composant correspondant) et représentée par une classe labellisée Cl_i . Ainsi, deux historiques de données ayant la même valeur EOL appartiennent à la même classe et possèdent le même label. Chaque indicateur de santé extrait à l’instant t à partir des données de test sera considéré comme un point de dimension égale à quatre (moyenne, variance, pente et point d’intersection du résidu extrait en utilisant l’EMD avec l’axe des ordonnées) et noté α . Supposons N_i points dans la classe Cl_i avec :

$$\sum_i N_i = N. \quad (3.37)$$

Pour affecter un nouveau point α à une classe Cl_i , on trace une sphère centrée sur α et contenant I points. Dans le cas où la sphère a un volume V et contient I_i points de la classe Cl_i , alors la

densité de probabilité associée à α est définie par :

$$p(\alpha) = \frac{I}{N \times V} \quad (3.38)$$

De la même manière, la densité estimée associée à chaque classe est donnée par l'expression suivante :

$$p(\alpha|Cl_i) = \frac{I_i}{N_i \times V} \quad (3.39)$$

et les densités de probabilités *a priori* sont exprimées par :

$$p(Cl_i) = \frac{N_i}{N} \quad (3.40)$$

En combinant les équations (3.37), (3.38) et (3.39) et en utilisant le théorème de Bayes, on obtient la probabilité *a posteriori* de la classe membre du nouveau point et donc de sa valeur EOL.

$$p(Cl_i|\alpha) = \frac{p(\alpha|Cl_i) \times p(Cl_i)}{p(\alpha)} = \frac{I_i}{I} \quad (3.41)$$

Pour minimiser l'erreur de classification (ou plutôt de non classification), le point α doit être affecté avec une large probabilité *a posteriori*. La figure 3.18 illustre l'utilisation de l'algorithme kNN à l'instant t . Pour rappel, dans nos travaux relatifs à cette partie, les indicateurs de santé sont construits en utilisant la méthode EMD à partir de données issues de tests de vieillissement accéléré réalisés sur plusieurs composants de la même famille.




FIGURE 3.18: Recherche des indicateurs de santé (Health Indicators : HI) les plus proches des classes apprises hors ligne.

L'un des inconvénients de l'algorithme kNN réside dans le fait que le résultat de classification dépend de la base d'apprentissage. Si l'indicateur de santé test n'est pas proche de ceux appris hors ligne, alors l'erreur de classification sera élevée. Ce problème est illustré sur la figure 3.19. Supposons un nouvel indicateur de santé extrait pour un composant dont la valeur EOL est égale 100 cycles. Dans la base d'apprentissage, seuls les cas avec 148 cycles et 55 cycles sont présents. Le kNN classera quand même le nouvel indicateur de santé dans l'une des classes et l'erreur sera, pour l'une ou l'autre des classes, élevée.

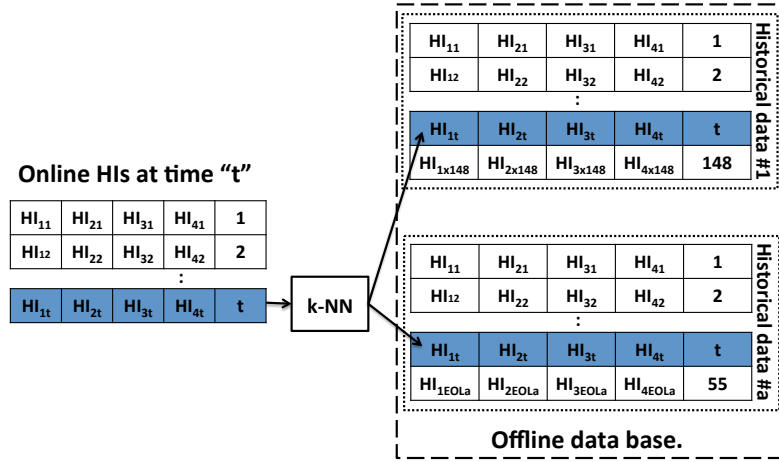


FIGURE 3.19: L'estimation du RUL par le kNN peut conduire à des erreurs élevées.

4.2 Processus de Gauss pour la régression

Pour éviter d'avoir des erreurs de classification élevées avec le kNN, nous proposons d'utiliser un modèle de régression, plus particulièrement le processus de Gauss pour la régression (GPR). Ce dernier est une approche probabiliste utilisée pour modéliser l'incertitude sur des données et pour réaliser de l'inférence Bayésienne [124].

Dans la description qui suivra, on notera x les indicateurs de santé appris hors ligne, et pris comme entrées du modèle de régression à l'instant t , et y les valeurs EOL correspondantes prises comme sorties du modèle. L'idée est alors de construire un modèle permettant d'exprimer la relation entre les entrées et la sortie, ce modèle est ensuite utilisé pour prédire la sortie (EOL) en fonction d'une nouvelle entrée (indicateur de santé)(voir figure 3.20).

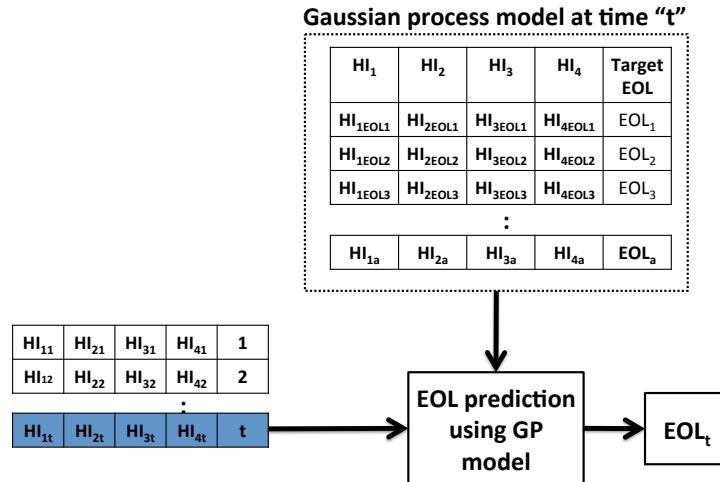


FIGURE 3.20: Relation entre les entrées (indicateurs de santé hors ligne) et les sorties correspondantes (EOL).

Pour trouver la relation entre l'entrée x et la sortie $y = f(x)$, le GPR définit une probabilité *a priori* pour la sortie $f(x)$ sous forme d'une distribution sur des fonctions spécifiées par le

processus de Gauss (Gaussian Process : GP).

$$y = f(x) + \mathcal{N}(0, \sigma_n^2) \quad (3.42)$$

où $\mathcal{N}(0, \sigma_n^2)$ représente un bruit Gaussien de moyenne zéro et de variance σ_n^2 . Un GP est une extension des distributions Gaussiennes multivariées en dimensions infinies. La fonction GP $f(x)$ est définie par une fonction moyenne $m(x)$ et une fonction covariance $k(x, x')$ obtenue sur le vecteur d'entrée x .

$$f(x) = \mathcal{GP}(m(x), k(x, x')) \quad (3.43)$$

avec

$$m(x) = E[f(x)] \quad (3.44)$$

et

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (3.45)$$

La valeur de la fonction covariance exprime la relation entre les observations. L'une des formes utilisées pour cette fonction est le carré d'une exponentielle :

$$k(x, x') = \sigma_f^2 \exp\left(\frac{-(x - x')^2}{2l^2}\right) + \sigma_n^2 \delta(x, x') \quad (3.46)$$

où x et x' sont deux observations, l un paramètre de normalisation (scaling parameter), σ_f^2 la variance maximale autorisée, σ_n^2 la variance du bruit et $\delta(x, x')$ la fonction de Kronecker (Kronecker delta function).

Étant donnée une nouvelle observation y_* , le but d'un GPR est de calculer la probabilité *a posteriori* $p(y_*|y)$, c'est à dire la probabilité d'avoir la donnée test y_* connaissant les données d'apprentissage y . Puisque dans le GP on suppose que les données peuvent être représentées comme des échantillons pris d'une distribution Gaussienne multivariée, la distribution de probabilité *a posteriori* peut être exprimée par :

$$\begin{bmatrix} y \\ y_* \end{bmatrix} \sim \mathcal{N}\left(\begin{bmatrix} \mu \\ \mu_* \end{bmatrix}, \begin{bmatrix} K & K_*^T \\ K_* & K_{**} \end{bmatrix} \right)$$

où $\mu = m(x)$ est le vecteur moyenne des données d'apprentissage, $\mu_* = m(x_*)$ le vecteur moyenne des données test, K est la covariance des données d'apprentissage, K_* la covariance des données apprentissage-test, K_{**} la covariance des données test et T représente la transposée d'une matrice. La probabilité *a posteriori* pour y_* suit une distribution Gaussienne :

$$y_*|y \sim \mathcal{N}(\mu_* + K_* K^{-1}(y - \mu), K_{**} - K_* K^{-1} K_*^T) \quad (3.47)$$

où la meilleure estimation pour y_* est la moyenne de la distribution :

$$\bar{y}_* = \mu_* + K_* K^{-1}(y - \mu) \quad (3.48)$$

L'incertitude dans l'estimation de y_* est représentée par la variance :

$$\text{var}(y_*) = K_{**} - K_* K^{-1} K_*^T \quad (3.49)$$

5 Conclusion

Nous avons abordé dans ce chapitre la problématique de modélisation de la dégradation du composant critique. Tout comme en automatique, où le modèle de comportement est primordial pour l'élaboration de lois de commande, le modèle de dégradation joue un rôle décisif dans la mise en œuvre du processus de PHM (détection, diagnostic, pronostic et aide à la décision).

Dans l'approche de pronostic guidée par les données, les modèles de dégradation sont obtenus par apprentissage sur des caractéristiques et des indicateurs de santé construits à partir de signaux bruts. Pour cela, il nous a fallu des outils de modélisation performants et faciles d'utilisation. Notre choix s'est alors porté sur des outils issus du domaine de l'intelligence artificielle, notamment les réseaux Bayésiens dynamiques, les machines à vecteurs de support et les processus de Gauss pour la régression. Ces outils permettent de prendre en compte les spécificités des données d'entrée (incertitudes, non linéarités, non stationnarités, etc.) et d'obtenir des résultats faciles à comprendre et à interpréter par l'utilisateur.

Les réseaux Bayésiens dynamiques sont une généralisation des chaînes de Markov cachées et des filtres de Kalman. Ils permettent de représenter, dans un graphe acyclique orienté et déroulé dans le temps, l'évolution de la dégradation du composant critique sous forme d'un vecteur d'état. Dans ce cas, les modèles de dégradation sont appris à partir de matrices de caractéristiques. Les modèles obtenus tiennent compte des données d'entrée et des conditions de fonctionnement et fournissent en sortie une estimation à tout instant de l'état de santé du composant (aspect traité dans le chapitre suivant).

Les machines à vecteurs de support et les processus de Gauss pour la régression s'avèrent plus adaptés pour la modélisation des incertitudes et des non linéarités de séries temporelles que les régressions classiques. Nous les avons utilisés dans ce chapitre pour modéliser les indicateurs de santé.

L'approche de modélisation que nous avons proposée repose sur deux phases : une première phase d'apprentissage et une seconde phase d'exploitation des modèles. La phase d'apprentissage consiste à estimer les paramètres des modèles (réseaux Bayésiens dynamiques, machines à vecteurs de support et processus de Gauss pour la régression) à partir des caractéristiques et des indicateurs de santé disponibles. Une fois ces paramètres sont appris, les modèles deviennent utilisables pour estimer l'état courant du composant et prédire son état futur ; ces aspects seront abordés dans le chapitre suivant.

En dépit des résultats encourageants obtenus sur cette partie, de nombreux verrous restent à lever. Néanmoins, deux d'entre eux nous semblent particulièrement pertinents. Le premier concerne la validation du modèle. Il s'agit de s'assurer que le modèle généré décrit fidèlement le comportement de la dégradation en tenant compte du contexte et des conditions d'utilisation. Cela passe par une démarche itérative de « vérification - correction » du modèle et nécessite un investissement important. Le second consiste à réduire les temps d'apprentissage et d'inférence. Ces deux verrous conduisent à la recherche d'un compromis « optimal » entre précision et complexité.

Les modèles générés dans ce chapitre seront utilisés dans le chapitre suivant pour estimer l'état courant du composant, prédire son état futur et calculer sa durée de fonctionnement avant défaillance.

Chapitre 4

Évaluation de l'état de santé et prédiction du RUL

1 Introduction

Les composants des systèmes industriels subissent des dégradations durant leur durée de vie. L'évolution de ces dégradations (figure 4.1) se reflète sur les données de surveillance fournies par les capteurs et par conséquent, sur les caractéristiques et les indicateurs de santé générés.




FIGURE 4.1: Initiation et évolution d'une dégradation.

Dans ce chapitre nous exploitons les modèles obtenus dans le chapitre 3 et les observations courantes pour continuellement évaluer l'état de santé du composant critique (Health Assessment) et prédire sa durée de fonctionnement avant défaillance (pronostic).

L'évaluation de l'état de santé est une tâche réalisée en ligne et consiste à donner à tout instant une estimation de l'état du composant. En effet, durant son utilisation, ce dernier s'il n'est pas entretenu s'éloignera de plus en plus de son état nominal pour atteindre son état défaillant (figure 4.2).

Le pronostic vise à calculer la durée de fonctionnement avant défaillance (RUL) du composant en connaissant son état courant et ses futures conditions d'utilisation. Cette tâche est également réalisée en ligne et fait appel aux modèles appris dans la phase hors ligne et aux observations courantes (caractéristiques et/ou valeurs des indicateurs de santé). Le calcul du RUL résulte d'une prédiction de l'état du composant et d'un seuil de défaillance. Les seuils peuvent être




FIGURE 4.2: Évolution de l'état de santé du composant : représentation par un ensemble de caractéristiques (à gauche) et par un indicateur de santé (à droite).

obtenus de différentes manières : fixés par l'expert du système, déterminés statistiquement sur la base des données du retour d'expérience ou appris expérimentalement à partir de tests de vieillissement accéléré. Comme on peut le constater sur la figure 4.3, l'incertitude est inhérente au pronostic. Elle intervient principalement dans les prédictions et dans les seuils de défaillance.




FIGURE 4.3: Illustration du RUL.

La performance du pronostic réalisé sur un composant critique peut être évaluée en utilisant différentes métriques proposées et publiées en PHM. Parmi elles on peut citer l'exactitude, la précision, l'horizon temporel de pronostic et la moyenne absolue de l'erreur relative des prédictions [91, 128, 155].

Ce chapitre résume nos principales contributions liées à l'estimation de l'état de santé et au pronostic de défaillances des composants critiques. Ces contributions ainsi que les applications concernées ont été obtenues dans le cadre des thèses de D. A. Tobon-Mejia et d'A. Mosallam et du post-doctorat d'A. Soualhi. Elles sont formulées sous forme de trois approches, toutes ayant pour objectifs de modéliser la dégradation, d'estimer l'état courant, de prédire l'état futur et de calculer le RUL de composants critiques. La première approche fait appel aux réseaux Bayésiens dynamiques et utilise une matrice de caractéristiques, la deuxième approche repose sur l'utilisation du processus de Gauss pour la régression sur les indicateurs de santé et enfin, la troisième approche utilise les machines à vecteurs de support pour la régression appliquée également sur les indicateurs de santé. Ces trois approches sont décrites dans les trois sections suivantes.

Les contributions résumées dans ce chapitre ont été présentées dans différentes conférences in-

ternationales [99, 149] et ont fait l'objet de publications dans des revues internationales avec comités de lecture [16, 17, 91, 98, 134, 148, 150].

2 Approche utilisant les MoG-HMMs et les RBDs

La première contribution fait appel aux MoG-HMMs représentés par des RBDs pour modéliser la dégradation du composant critique, évaluer son état de santé courant et prédire son RUL. Elle est réalisée en deux phases : une première phase d'apprentissage et une seconde phase d'exploitation (ou de test) (figure 4.4). Dans la première phase, les signaux délivrés par les capteurs sont traités afin d'extraire des caractéristiques pertinentes qui révèlent le phénomène de dégradation subi par le composant critique. Ces caractéristiques sont ensuite utilisées pour apprendre des modèles capables de renseigner sur les différents états de santé du composant durant son utilisation. Dans la seconde phase, les modèles appris sont exploités pour identifier en ligne l'état du composant et estimer son RUL.

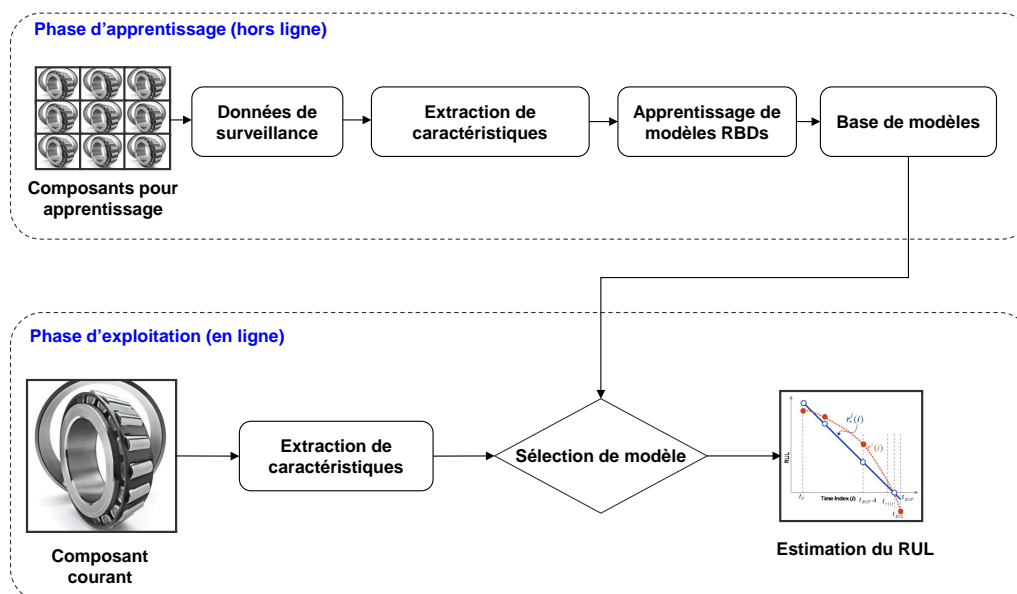


FIGURE 4.4: Pronostic de défaillances basé sur l'utilisation de RBDs.

L'originalité de cette première approche réside dans le fait que les durées de séjour dans les différents états du modèle MoG-HMM ne suivent pas une loi exponentielle. En effet, contrairement aux HMMs classiques, dans cette approche les durées de séjour sont apprises à partir des données de surveillance, ce qui permet d'avoir des durées représentatives et des prédictions du RUL plus précises. En outre, le modèle MoG-HMM considéré peut prendre n'importe quelle topologie, gauche-droite, droite gauche ou ergodique.

Phase d'apprentissage

C'est la première phase de la méthode et elle est réalisée hors ligne. Ici les données brutes délivrées par les capteurs installés pour surveiller le composant sont traitées pour extraire des caractéristiques pertinentes pour l'apprentissage de modèles MoG-HMMs (figure 3.10) représentant les historiques de dégradation. Dans cette approche chaque signal de surveillance (appartenant à un historique γ) est transformé en une matrice D_γ^γ où chaque colonne (de Y cellules) correspond à une image instantanée des caractéristiques à l'instant t pour l'historique γ .

$$\text{Données brutes de l'historique } \gamma \rightarrow D_{\Upsilon}^{\gamma}(t) = \begin{pmatrix} D_1(t) & \dots & D_1(T^{\gamma}) \\ \vdots & \ddots & \vdots \\ D_Y(t) & \dots & D_Y(T^{\gamma}) \end{pmatrix} \quad \forall \begin{matrix} 1 \leq t \leq T^{\gamma} \\ 1 \leq \Upsilon \leq Y \\ 1 \leq \gamma \leq H \end{matrix} \quad (4.1)$$

où T^{γ} est la durée totale de l'historique γ et H le nombre total d'historiques.

Ces caractéristiques sont utilisées pour estimer les paramètres π , A et B des modèles MoG-HMMs ainsi que leur paramètres temporels (durée de séjour dans chaque état). Les paramètres π , A et B sont obtenus par le biais de l'algorithme Expectation-Maximisation (EM) de Baum-Welch [14] généralisé aux RBDs par K.P. Murphy [105]. Dans l'approche que nous proposons, et afin de laisser le modèle MoG-HMM prendre la forme la plus appropriée, ces paramètres sont initialisés de façon aléatoire. Le nombre d'états N de chaque MoG-HMM est défini en fonction du composant critique étudié. Par exemple, pour un roulement, trois états peuvent suffire [151], tandis que pour un outil de coupe d'une machine à commande numérique, cinq états sont nécessaires afin de caractériser les différentes régions d'usure [147]. Concernant l'estimation du nombre optimal de mélanges de Gaussiennes M de la matrice d'observations B , une analyse d'optimisation est réalisée afin de définir le nombre de mélanges qui maximise la vraisemblance du modèle obtenu par l'algorithme EM.

Les paramètres temporels des MoG-HMMs sont estimés en utilisant l'algorithme de Viterbi [159]. Ce dernier permet d'estimer la séquence d'états (figure 4.5) visités par un historique de données γ à partir des paramètres π , A et B du modèle correspondant et des observations (caractéristiques) $O_t = D_{\Upsilon}^{\gamma}(t)$ courantes. En considérant cette séquence d'états et en supposant que la durée de séjour dans chaque état suit une loi normale, on peut estimer la durée de séjour moyenne $\mu_d(x_i)$ dans chaque état et son écart type $\sigma_d(x_i)$ (équation 4.2). La séquence d'états obtenue est également utilisée pour identifier l'état final x_{final} qui correspond à la défaillance du composant (figure 4.5).

$$\begin{aligned} \mu_d(x_i) &= \frac{1}{\Omega} \sum_{w=1}^{\Omega} \Delta(x_{iw}) \\ \sigma_d(x_i) &= \sqrt{\frac{1}{\Omega} \sum_{w=1}^{\Omega} [\Delta(x_{iw}) - \mu(\Delta(x_i))]^2} \end{aligned} \quad (4.2)$$

$\Delta(\cdot)$ est la durée de la visite, i l'indice de l'état, w l'indice de visite et Ω_{x_i} le nombre total de visites de l'historique de données étudié γ . Une représentation compacte de chaque RBD appris, et représentant un modèle MoG-HMM, est alors donnée par l'expression (4.3).

$$\lambda_{\text{RBD}} = (\pi, A, B, \mu_d(x_i), \sigma_d(x_i), \Omega_{x_{\text{final}}}) \quad (4.3)$$

Phase d'exploitation

Les modèles MoG-HMMs obtenus dans la phase d'apprentissage sont utilisés dans cette phase pour détecter l'état courant du composant critique et estimer son RUL. Pour cela, les caractéristiques extraites des signaux de surveillance du composant test sont continuellement injectées dans les modèles appris afin de sélectionner celui qui représente le mieux les observations courantes. Le processus de sélection est basé sur le calcul des probabilités $P[O|\lambda_{\text{RBD}}]$ des différents modèles par rapport aux observations courantes. Le modèle sélectionné est ensuite utilisé pour détecter l'état courant, estimer le RUL du composant et calculer l'intervalle de confiance du pronostic réalisé. Cela est réalisé en cinq étapes décrites ci-dessous.

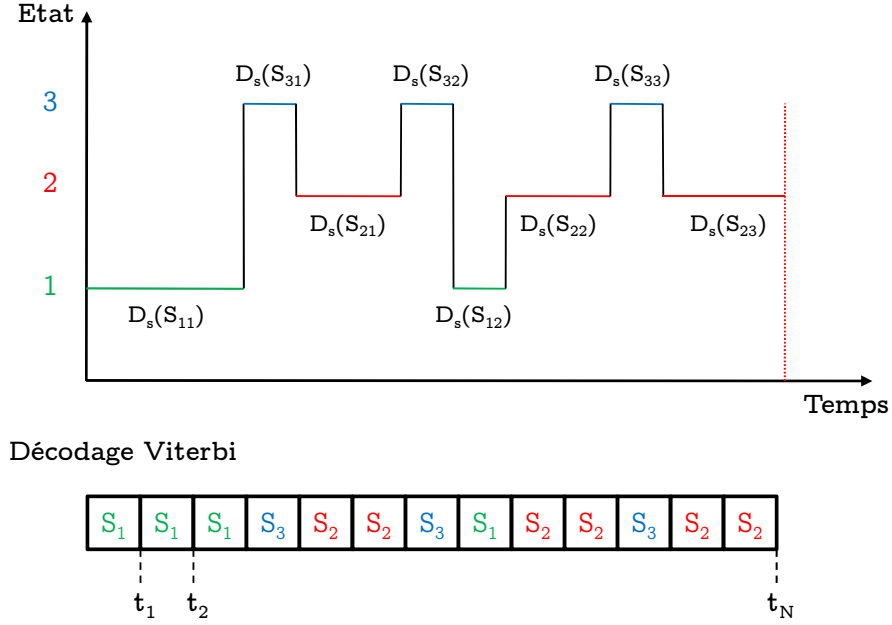


FIGURE 4.5: Exemple de séquence d'états obtenue par l'algorithme de Viterbi.

1. La première étape consiste à identifier le modèle λ_{RBD} , parmi les modèles appris, qui représente le mieux la séquence d'observations courantes (figure 4.6). Le meilleur modèle correspond à celui qui donne la probabilité $P[O|\lambda_{RBD}]$ la plus élevée calculée en utilisant l'algorithme « forward-backward ».

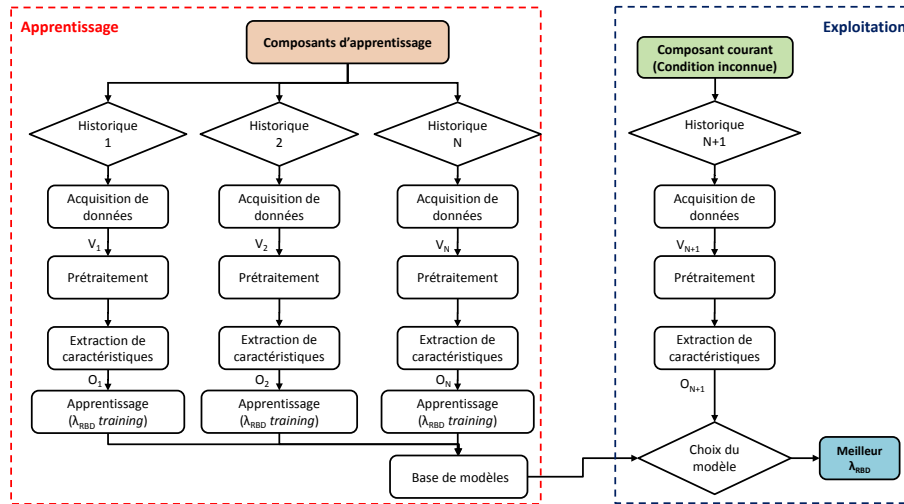


FIGURE 4.6: Sélection du meilleur modèle représentant les observations courantes.

2. La deuxième étape correspond à l'identification de l'état courant du composant. Pour cela, l'algorithme de Viterbi est appliqué sur le modèle RBD sélectionné pour calculer la séquence d'états qui correspond aux observations courants. L'état qui se répète le plus à la fin de la séquence est retenu comme l'état actif (état courant du composant).

$$\text{séquence d'états} = (x_1, x_2, \dots, x_t), \quad (4.4)$$

avec t = temps actuel.

$$\text{Derniers états} = (x_{t-l}, \dots, x_{t-2}, x_{t-1}, x_t), \quad (4.5)$$

avec l = facteur d'oubli.

3. La troisième étape consiste à utiliser l'état courant, l'état final et la matrice de probabilités de transition A du RBD sélectionné pour trouver le chemin qui part de l'état courant vers l'état final (défaillance). Pour cela toutes les probabilités de transition a_{ij} qui sont non nulles sont utilisées pour définir le chemin le plus court en considérant seulement une visite par état. De la même façon, le chemin le plus long est celui qui traverse un maximum d'états.




FIGURE 4.7: Définition des chemins court et long.

4. Enfin, dans la quatrième étape, les chemins définis précédemment sont utilisés pour calculer la valeur du RUL du composant critique. Cette valeur est obtenue en utilisant les durées de séjour estimées dans chaque état du modèle RBD sélectionné. La valeur de confiance associée au RUL est calculée en utilisant l'écart-type sur les durées de séjour. Le coefficient de confiance n pour un intervalle α est calculé selon l'équation suivante :

$$\Phi(n) = \frac{\alpha + 100}{200} \quad (4.6)$$

où Φ est une loi normale centrée et $\alpha \in [0, 100]$. Trois valeurs de RUL peuvent alors être estimées : RUL supérieur ($\mu + n \cdot \sigma$), RUL moyen et RUL inférieur ($\mu - n \cdot \sigma$).

$$\text{RUL}_{upper}(t) = \sum_{i=\text{current state}}^N [v_i \cdot \mu_d(x_i) + n \cdot \sigma_d(x_i)] - \tilde{t}_{ac} \quad (4.7)$$

$$\text{RUL}_{mean}(t) = \sum_{i=\text{current state}}^N v_i \cdot \mu_d(x_i) - \tilde{t}_{ac} \quad (4.8)$$

$$\text{RUL}_{lower}(t) = \sum_{i=\text{current state}}^N [v_i \cdot \mu_d(x_i) - n \cdot \sigma_d(x_i)] - \tilde{t}_{ac} \quad (4.9)$$

$$\forall i \in \text{état dans le chemin actif} \wedge v_i \in [0, \Omega_{x_i}]$$

Dans les equations (4.7), (4.8) et (4.9) \tilde{t}_{ac} représente le temps passé par le composant dans l'état actif. Ce temps est estimé par l'équation suivante :

$$\tilde{t}_{ac} = \begin{cases} 0 & \text{si } x_t \neq x_{t-1} \\ \tilde{t}_{ac}(t-1) + \Delta t & \text{si } x_t = x_{t-1} \end{cases} \quad (4.10)$$

La variable ν_i représente le nombre de visites restantes avant d'atteindre l'état x_i . Cette variable est initialisée au nombre de visites pour arriver à l'état x_i , c'est à dire $\nu_i = \Omega_{x_i}$. La variable ν_i est décrémentée d'une unité à chaque fois qu'un changement d'état ($x_t \neq x_{t-1} \wedge \lambda_{DBN}(t-1) = \lambda_{DBN}(t)$) ou de modèle ($\lambda_{DBN}(t) \neq \lambda_{DBN}(t-1)$) est détecté.

2.1 Application aux roulements

L'approche décrite dans la section précédente a été appliquée, dans un premier temps, sur des données liées aux roulements testés sur la plateforme Pronostia. Dans cette application, six historiques ont été utilisés. Les conditions de fonctionnement correspondent à une vitesse de rotation égale à 1800 tr/min et une force radiale appliquée aux roulements égales à 4000 N (tableau 4.1).

TABLE 4.1: Résumé des historiques des roulements utilisés dans Pronostia.

Historique	Vitesse (tr/min)	Charge (N)	Durée
1	1800	4000	3H25
2	1800	4000	6H50
3	1800	4000	6H48
4	1800	4000	6H16
5	1800	4000	1H00
6	1800	4000	1H12

Pour l'estimation du RUL et de la confiance associée, les données des roulements 1, 3, 4, 5, et 6 ont été utilisées dans la phase d'apprentissage pour estimer les paramètres des RBDs représentant les dégradations, tandis que les données de l'historique 2 ont été utilisées dans la phase test.

Deux types de caractéristiques ont été extraites des signaux vibratoires fournis par les deux accéléromètres placés sur les roulements : caractéristiques temporelles [69] (RMS, moyenne, valeur pic, facteur de crête, kurtosis, etc.) et caractéristiques temps-fréquence (énergies à différents niveaux de décomposition de la WPD). Un exemple de caractéristiques temporelles extraites de l'accéléromètre horizontal est montré sur la figure 4.8.

L'inconvénient des caractéristiques temporelles est l'absence de la dimension fréquentielle. Pour y remédier, nous avons fait appel à la décomposition en paquets d'ondelettes (WPD). La figure 4.9 montre deux résultats des coefficients d'énergie extraits des derniers niveaux de décomposition de la bande de fréquence 1 - 800 Hz.

Durant la phase d'apprentissage des modèles MoG-HMMS, représentés par des RBDs, deux paramètres ont été requis : il s'agit du nombre d'états N et du nombre de mélanges de Gaussiennes M . Dans cette application, le nombre d'états est fixé à trois. Ce choix est justifié par le fait que




FIGURE 4.8: Caractéristiques extraites de l'accéléromètre radial : (a) RMS, et (b) kurtosis.




FIGURE 4.9: Pourcentages d'énergie extraits de l'accéléromètre vertical en utilisant la WPD sur la bande 1 - 800 Hz.

la dégradation du roulement peut être représentée par trois niveaux : nominal, dégradé et défaillant. Pour la définition du nombre de mélanges, une analyse *a priori* a d'abord été réalisée. Les résultats de cette analyse sont montrés sur la figure 4.10. Nous avons fait varier le nombre de mélanges lors de l'apprentissage du modèle de chaque historique de données. Ensuite, pour un nombre de mélanges donné, nous avons calculé la vraisemblance $P[\mathcal{O}|\lambda_{\text{DBN}}]$. Le nombre de mélanges retenu est alors pris comme le plus petit nombre à partir duquel la vraisemblance commence à converger. Dans la suite de l'application ce nombre est fixé à quatre.




FIGURE 4.10: Analyse de sensibilité pour déterminer le nombre de mélanges M .

Les paramètres π , A et B des RBDs représentant les dégradations des roulements sont appris en utilisant l'algorithme de Baum-Welch sur les caractéristiques extraites (temporelles et temps-fréquence). Un exemple de séquence obtenue en utilisant l'algorithme de Viterbi est montré sur la figure 4.11. Les paramètres temporels du RBD liés à chaque historique sont donnés sur les tableaux 4.2 et 4.3.




FIGURE 4.11: Séquence d'états obtenue en utilisant l'algorithme de Viterbi sur l'historique 1.

Dans la phase d'exploitation, les modèles λ_{RBD} construits lors de la phase d'apprentissage sont utilisés pour estimer le RUL et évaluer la performance du pronostic réalisé. Dans cette application, le facteur d'oubli est fixé à 10, ce qui veut dire que l'état courant dans les dix dernières minutes est choisi comme état actif le plus probable. Pour l'estimation des limites de confiance, $\text{RUL}_{\text{upper}}$ et $\text{RUL}_{\text{lower}}$, un intervalle de 95% a été défini ($\alpha = 95$).

Pour la mise en œuvre des métriques de pronostic [91, 128], nous avons fixé la valeur de α_c à

TABLE 4.2: Paramètres temporels des modèles appris à partir des caractéristiques temporelles.

État	Paramètres (min)	Expérimentation				
		1	3	4	5	6
x_1	μ_d	4,1	7,83	9	1	1,37
	σ_d	1,9	3,3	0	0	0,74
	Ω	11	6	1	12	8
x_2	μ_d	6,8	6,6	366	17,5	3,27
	σ_d	5,6	2	0	9,19	3,84
	Ω	10	5	1	2	11
x_3	μ_d	2,66	81,7	1	1	8,66
	σ_d	9,07	126,3	0	0	5,13
	Ω	3	4	1	12	3

TABLE 4.3: Paramètres temporels des modèles appris à partir des caractéristiques temps-fréquence.

État	Paramètres (min)	Expérimentation				
		1	3	4	5	6
x_1	μ_d	63	18,25	29,25	10	8,33
	σ_d	0	24,54	38,9	9,84	9,29
	Ω	1	4	4	3	3
x_2	μ_d	20,5	62,5	50,33	12	10
	σ_d	3,53	27,58	79,46	11,31	13
	Ω	2	2	3	2	3
x_3	μ_d	20,5	69,67	108	1,66	6
	σ_d	17,68	50,14	0	1,15	2,64
	Ω	2	3	1	3	3

0,3. Cette valeur permet de tolérer des déviations de l'ordre de 30% du RUL réel. Pour le calcul de $P_{\alpha_c - \lambda_c}$, λ_c a été fixé à 0,5 pour vérifier si au milieu ($T/2$) de l'historique des données les prédictions sont à l'intérieur de l'intervalle de confiance α_c . Concernant l'exactitude relative, elle est évaluée pour trois valeurs de λ_c (0,75, 0,5 et 0,25) correspondant à trois intervalles de temps : le début, le milieu et la fin de l'historique de données. Les résultats de pronostic sont montrés sur la figure 4.12. Les RULs donnés sur la figure 4.12-(a) sont obtenus avec des caractéristiques temporelles tandis que ceux de la figure 4.12-(b) sont obtenus avec des coefficients d'énergie de la WPD. Les résultats des métriques de performance du pronostic utilisant les caractéristiques temporelles et temps-fréquence sont donnés sur le tableau 4.4. On peut y constater que le RUL estimé est relativement précis comme le confirme la valeur de l'exactitude qui est égale à 0,7874. La précision obtenue est également bonne, avec une dispersion de 4,91 minutes. Enfin, la valeur de la mesure HP (Horizon de Prédiction) est égale à 409 minutes, ce qui signifie que le RUL estimé entre dans l'intervalle de confiance une minute après le lancement des prédictions.




FIGURE 4.12: Estimation du RUL pour l'historique 2 : (a) caractéristiques temporelles et (b) caractéristiques temps-fréquence.

TABLE 4.4: Métriques de performance du pronostic.

	Exactitude	Précision	MAPER	HP	$P_{\alpha-\lambda}$	ER
$RUL_{Temporal}^{mean}$	0,7874	4,91	26,96	409	No	[0,89 0,84 0,69]
$RUL_{Wavelets}^{upper}$	0,309	56,79	367,4	False	No	[0,33 - 0,12 - 1,25]
$RUL_{Wavelets}^{mean}$	0,9426	37,18	6,5	405	Yes	[0,9 0,99 0,98]
$RUL_{Wavelets}^{lower}$	0,402	88,16	91,93	False	No	[0,15 0 0]

Les résultats du pronostic obtenus en utilisant les caractéristiques temps-fréquence sont montrés sur la figure 4.12-(b). On peut y constater que le RUL prédit est à l'intérieur de l'intervalle de confiance durant toute la durée de l'expérimentation. Ce résultat peut être expliqué par le fait que les caractéristiques temps-fréquence sont plus sensibles à la dégradation du roulement. Nous avons également de bonnes estimations du RUL moyen (RUL_{mean}), une bonne valeur de l'horizon de prédiction ($HP = 405 \text{ min}$) et des exactitudes relatives proches de 1 ($ER = [0,9 0,99 0,98]$).

2.2 Application à l'usure des outils de coupe

Les machines d'usinage à commande numérique sont largement utilisées dans l'industrie. Statistiquement, 20% des pannes de ces machines sont attribuées à l'usure et rupture des outils de coupe conduisant à des pertes de productivité [68]. La prédiction de l'usure de ces outils peut ainsi aider à améliorer la disponibilité, la fiabilité et la sécurité des machines tout en assurant un état de surface acceptable et des coûts de maintenance faibles.

L'approche d'estimation de l'état de santé et de prédiction du RUL que nous avons proposée dans la section 2 a été également appliquée sur les données du « prognostic data challenge 2010 » [145]. Ces données correspondent à différents historiques d'outils de coupe utilisés jusqu'à leur usure complète. Les auteurs de ces expérimentations ont enregistré des données de capteurs de force, d'accéléromètres et d'émissions acoustiques durant le processus de coupe et mesuré la quantité d'usure après chaque coupe.




FIGURE 4.13: Le banc d'essai d'usinage [145].

Les données expérimentales issues de cette application correspondent à trois tests réalisés sous des conditions de fonctionnement constantes : vitesse de rotation de l'outil de coupe égale à 10400 tr/min , vitesse d'avance de l'outil de 1555 mm/min , profondeur de coupe radiale Y égale à $0,125 \text{ mm}$ et profondeur de coupe axiale Z fixée à $0,2 \text{ mm}$. Les données ont été enregistrées à une fréquence de 50 kHz . Trois jeux de données ont été utilisés : deux pour l'apprentissage (outils 1 et 4) et un pour le test (outil 6). Chaque outil effectue 315 coupes, il est considéré hors d'usage à la fin de l'historique de données qui lui est associé. Durant les coupes, trois types de signaux ont été enregistrés : force, vibrations et émissions acoustiques.

Avant de procéder à l'apprentissage des modèles RBDs, nous avons réalisé un partitionnement (clustering) des données de coupe afin de distinguer les différents niveaux d'usure de chaque outil. La figure 4.14 montre le résultat du nombre de coupes des différents clusters obtenus en utilisant l'algorithme k-means. On peut constater par exemple que pour l'outil 1, sur les 315 coupes, les 32 premières appartiennent au premier niveau d'usure, les 126 suivantes au niveau d'usure 2, les 59 suivantes au niveau d'usure 3, les 51 suivantes au niveau d'usure 4 et enfin les 47 dernières coupes sont classées dans le niveau d'usure 5.

Lors de la phase d'apprentissage, les modèles MoG-HMMs appris (représentés par des RBDs) sont divisés en deux groupes. Le premier groupe contient les modèles correspondants aux niveaux globaux d'usure (chaque niveau est une sorte de moyenne sur tous les historiques de données). Ces modèles sont stockés dans une base appelée base de modèles globaux d'usure. Le second groupe contient un modèle par niveau d'usure et par historique de données, il est nommé base de modèles locaux d'usure. Ainsi, si W représente les niveaux d'usure et H les historiques de

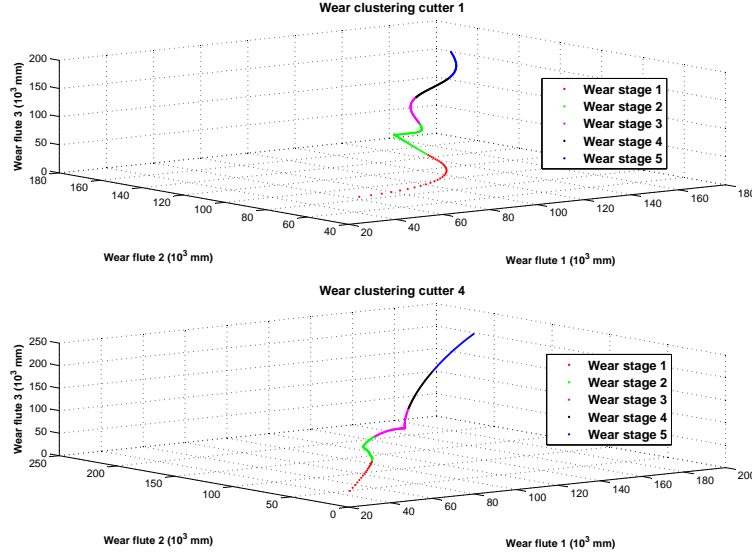


FIGURE 4.14: Les résultats de clustering.

données, la base de modèles globaux contient W modèles et celle des modèles locaux $W \times H$ modèles. Le second groupe permet d'obtenir la séquence d'états et de calculer la quantité d'usure pour chaque état. En utilisant l'algorithme de Viterbi, il est également possible de trouver les coupes appartenant à un état particulier (figure 4.15). Enfin, en supposant que l'usure dans chaque niveau suit une loi normale, on peut estimer la moyenne et l'écart-type de chaque usure Wr ainsi que la moyenne et l'écart-type de la variation d'usure entre deux coupes pour chaque état selon les équations (4.11) et (4.12).

$$\begin{aligned}\mu(Wr_w^h(S_i)) &= \frac{1}{T_c} \sum_{c=st}^{C_l} wr_w^h(c) \\ \mu(\Delta Wr_w^h(S_i)) &= \frac{1}{T_c} \sum_{c=st+1}^{C_l} (wr_w^h(c) - wr_w^h(c-1))\end{aligned}\tag{4.11}$$

$$\begin{aligned}\sigma(Wr_w^h(S_i)) &= \frac{1}{T_c} \sum_{c=st}^{C_l} [wr_w^h(c) - \mu(Wr_w^h(S_i))]^2 \\ \sigma(\Delta Wr_w^h(S_i)) &= \frac{1}{C_l} \sum_{c=st+1}^{T_c} [(wr_w^h(c) - wr_w^h(c-1)) - \mu(\Delta Wr_w^h(S_i))]^2\end{aligned}\tag{4.12}$$

Dans ces équations, wr_w^h représente l'usure associée au niveau w ($w = 1, \dots, W$) et l'historique h ($h = 1, \dots, H$), i l'indice de l'état, c l'indice de coupe, st le début de coupe, C_l la limite de coupe et $T_c = C_l - st + 1$. On obtient ainsi dans la phase d'apprentissage un modèle RBD compact donné par l'expression suivante :

$$\lambda = \left(RBD_w(\theta), RBD_w^h(\theta), \mu(Wr_w^h(S_i)), \mu(\Delta Wr_w^h(S_i)), \sigma(Wr_w^h(S_i)), \sigma(\Delta Wr_w^h(S_i)) \right)\tag{4.13}$$

Dans cette expression, λ représente le modèle, $RBD_w(\theta)$ sont les paramètres du RBD modélisant le comportement du niveau d'usure w et résument tous les historiques de données H , $RBD_w^h(\theta)$ sont les paramètres du RBD représentant le comportement du niveau d'usure w pour l'historique h , $\mu(Wr_w^h(S_i))$ et $\mu(\Delta Wr_w^h(S_i))$ représentent la moyenne de l'usure et la moyenne de la variation




FIGURE 4.15: Séquence d'états pour un historique d'évolution de l'usure.

TABLE 4.5: Paramètres estimés en (10^{-3} mm)

Paramètre	S_1	S_2	S_3
$\mu(Wr_1^1)$	31,9297	44,3904	51,9272
$\sigma(Wr_1^1)$	10,9088	6,8359	5,3714
$\mu(\Delta Wr_1^1)$	2,6165	2,0063	1,2211
$\sigma(\Delta Wr_1^1)$	0,6380	0,3199	0,1824

de l'usure de l'état i dans le niveau d'usure w calculées sur l'historique h . De la même façon, $\sigma(Wr_w^h(Si))$ et $\sigma(\Delta(Wr_w^h(Si)))$ représentent l'écart-type de l'usure et l'écart-type de la variation de l'usure dans l'état i pour le niveau d'usure w calculés sur l'historique h .

Dans cette application, les paramètres des MoG-HMMs, représentés par des RBDs, correspondant aux modèles globaux et aux modèles locaux sont d'abord initialisés aléatoirement. Ces MoG-HMMs sont contraints à une topologie gauche-droite. Ensuite, les caractéristiques extraites des signaux bruts sont injectées dans les algorithmes d'apprentissage afin de re-estimer les paramètres initialisés. Le nombre de Gaussiennes dans chaque MoG-HMM est fixé à deux. Quinze RBDs (cinq dans la base des modèles globaux et dix dans la base des modèles locaux) ont été générés en utilisant les algorithmes d'apprentissage de la boîte à outils proposée par K.P. Murphy [105]. Les valeurs des paramètres re-estimés π , A et M d'un modèle MoG-HMM lié au RBD global pour le premier niveau d'usure sont données ci-dessous.

$$\pi = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, A = \begin{pmatrix} 0,8 & 0,2 & 0 \\ 0 & 0,75 & 0,25 \\ 0 & 0 & 1 \end{pmatrix}, M = \begin{pmatrix} 0,4 & 0,6 \\ 0,5 & 0,5 \\ 0,58 & 0,42 \end{pmatrix}$$

La séquence d'états des coupes appartenant au premier niveau d'usure apprise de l'historique associé à l'outil 1 est montrée sur la figure 4.16. L'usure moyenne et la variation de l'usure moyenne ainsi que les écart-types associés pour cet historique sont donnés sur le tableau 4.5.

Lors de la phase de test, on injecte les observations courantes dans les modèles globaux appris pour sélectionner celui qui les représente le mieux et identifier le niveau d'usure w courant. On cherche ensuite le modèle local qui correspond aux observations connaissant le niveau d'usure. On applique alors l'algorithme de Viterbi sur le modèle sélectionné afin de trouver la séquence d'états cachés qui permet d'identifier l'usure courante et de calculer la quantité d'usure et la variation de la quantité d'usure. Cela est réalisé en choisissant l'état le plus persistant dans la

dernière séquence d'états obtenue. Cet état est sauvegardé dans une séquence globale d'états nommée $G_w^h(S_i)$ et stockée dans une cellule contenant les états courants et précédents.

$$\begin{aligned} \text{séquence d'état} &= (S_1, S_2, \dots, S_c), \\ \text{avec } c &= \text{coupe courante}, \\ \text{derniers états} &= (S_{c-p}, \dots, S_{c-2}, S_{c-1}, S_c), \\ \text{avec } p &= \text{dernières observations retenues} \end{aligned} \quad (4.14)$$

Enfin, la séquence d'états obtenue ainsi que les valeurs apprises $\mu(\text{Wr}_w^h(S_i))$, $\mu(\Delta(\text{Wr}_w^h(S_i)))$, $\sigma(\text{Wr}_w^h(S_i))$ et $\sigma(\Delta(\text{Wr}_w^h(S_i)))$ sont utilisées pour estimer la quantité d'usure de l'outil correspondant. L'état courant de chaque cellule est comparé à l'état précédent (cellule précédente). Si les états sont identiques, alors la moyenne de variation de l'usure $\mu(\Delta(\text{Wr}_w^h(S_i)))$ est ajoutée à celle du même état et les limites de confiance sont calculées en utilisant le facteur de confiance n . Sinon, l'usure et les limites de confiance sont mises à jour pour le nouvel état selon les équations (4.15), (4.16) et (4.17).

$$\widehat{\text{Wr}}_u(c) = \begin{cases} \mu(\text{Wr}_w^h(S_i)) + n \cdot \sigma(\text{Wr}_w^h(S_i)), \\ \text{If } [G_w^h(S_i)]_c = 1 \vee [G_w^h(S_i)]_c \neq [G_w^h(S_i)]_{c-1} \\ \widehat{\text{Wr}}_m(c-1) + [\mu(\Delta \text{Wr}_w^h(S_i)) + n \cdot \sigma(\Delta \text{Wr}_w^h(S_i))], \\ \text{If } [G_w^h(S_i)]_c = [G_w^h(S_i)]_{c-1} \end{cases} \quad (4.15)$$

$$\widehat{\text{Wr}}_m(c) = \begin{cases} \mu(\text{Wr}_w^h(S_i)), \\ \text{If } [G_w^h(S_i)]_c = 1 \vee [G_w^h(S_i)]_c \neq [G_w^h(S_i)]_{c-1} \\ \widehat{\text{Wr}}_m(c-1) + \mu(\Delta \text{Wr}_w^h(S_i)) \\ \text{If } [G_w^h(S_i)]_c = [G_w^h(S_i)]_{c-1} \end{cases} \quad (4.16)$$

$$\widehat{\text{Wr}}_l(c) = \begin{cases} \mu(\text{Wr}_w^h(S_i)) - n \cdot \sigma(\text{Wr}_w^h(S_i)), \\ \text{If } [G_w^h(S_i)]_c = 1 \vee [G_w^h(S_i)]_c \neq [G_w^h(S_i)]_{c-1} \\ \widehat{\text{Wr}}_m(c-1) + [\mu(\Delta \text{Wr}_w^h(S_i)) - n \cdot \sigma(\Delta \text{Wr}_w^h(S_i))], \\ \text{If } [G_w^h(S_i)]_c = [G_w^h(S_i)]_{c-1} \end{cases} \quad (4.17)$$

Enfin, les quantités d'usure estimées sont utilisées pour calculer le RUL. Ce dernier est obtenu en utilisant les informations sauvegardées dans les trois vecteurs obtenus dans la phase précédente




FIGURE 4.16: Séquence d'états.

$\widehat{\mathbf{W}}_r = (\widehat{\mathbf{W}}_{r_u}, \widehat{\mathbf{W}}_{r_m}, \widehat{\mathbf{W}}_{r_l})$. Chaque vecteur contenant les quantités d'usure est alors ajusté à un modèle polynômial $\hat{P}(\widehat{\mathbf{W}}_r, \beta)$ de même ordre que le niveau d'usure courant w .

$$\hat{P}(\widehat{\mathbf{W}}_r, \beta) = \sum_{i=0}^w \beta_i \widehat{\mathbf{W}}_r^i \quad (4.18)$$

L'évolution de la quantité d'usure combinée au seuil d'usure limite permet d'estimer le RUL. Ce dernier est obtenu selon l'équation suivante :

$$RUL(c) = \left(W_{r_{limit}} - \frac{\hat{P}(\widehat{\mathbf{W}}_{r_u}(t), \beta) + \hat{P}(\widehat{\mathbf{W}}_{r_m}(t), \beta) + \hat{P}(\widehat{\mathbf{W}}_{r_l}(t), \beta)}{3} \right) \quad (4.19)$$

Les résultats de prédiction de la quantité d'usure et d'estimation du RUL pour l'outil numéro 6 sont montrés sur la figure 4.17. Pour la prédiction du RUL, un seuil limite de $140 \times 10^{-3} \text{ mm}$ a été considéré.




FIGURE 4.17: Résultats de simulation : (a) estimation de l'usure pour l'outil 6, en utilisant les données des outils 1 et 4 comme données d'apprentissage, et (b) RUL prédit pour l'outil 6.

Dans cette section, nous avons montré l'applicabilité de l'approche proposée pour estimer l'état de santé et prédire le RUL de deux catégories de composants : les roulements et les outils de coupe. Cette approche repose sur la mise en œuvre d'un processus générique composé de l'extraction de caractéristiques (temporelles, fréquentielles et temps-fréquence) à partir de différents types de capteurs, l'apprentissage hors ligne des modèles de dégradation en utilisant les réseaux Bayésiens dynamiques et les algorithmes associés, et l'exploitation des modèles appris pour l'estimation en ligne de l'état de santé et le calcul du RUL de composants en cours de fonctionnement. Les résultats issus de ces applications montrent que les caractéristiques temps-fréquence donnent de meilleurs résultats que les caractéristiques temporelles. Cela pourrait être expliqué par le fait que les caractéristiques temporelles ne comportent pas la dimension fréquentielle de la dégradation. Ces résultats montrent également qu'il est possible d'étendre l'approche proposée à d'autres types de composants (engrenages, vis à billes, etc.) à condition que des données représentatives de l'évolution des dégradations soient disponibles.

3 Approche utilisant le processus de Gauss pour la régression

L'approche présentée dans la section 2 utilise comme données d'entrée une matrice de caractéristiques. Dans cette section, nous proposons une autre approche basée sur l'utilisation des indicateurs de santé. L'avantage de cette approche par rapport à la précédente réside dans le fait que les indicateurs de santé résultent d'un traitement avancé sur des données issues de la fusion de différents signaux bruts ou caractéristiques, ce qui les rend plus sensibles à la dégradation. Cette approche repose sur deux phases, une phase d'apprentissage et une phase de test. Ces phases sont montrées sur la figure 4.18 et décrites dans les paragraphes suivants.

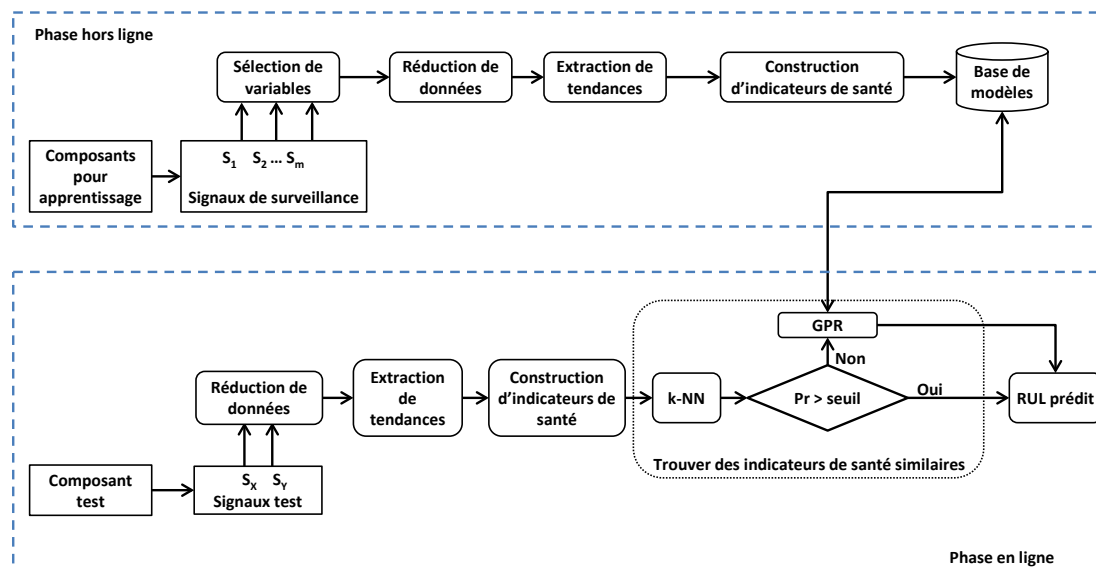


FIGURE 4.18: Approche de pronostic basée sur le k-NN et le processus de Gauss pour la régression.

Phase hors ligne

- Composants critiques pour l'apprentissage : ensemble de composants critiques de même type (exemple : n batteries de même référence) utilisés de leur état neuf à leur défaillance complète, selon les mêmes conditions de fonctionnement et environnementales, pour fournir des données représentatives de leur dégradation. Une partie de ces données est utilisée pour apprendre l'évolution de l'état de santé des composants.
- Signaux de surveillance : ils représentent les signaux fournis par les différents capteurs installés sur chaque composant critique pour surveiller son fonctionnement et renseigner sur sa dégradation.
- Sélection de variables (signaux) : pour chacun des composants critiques, on applique l'algorithme de sélection de variables présenté dans le chapitre 2, section 4 pour choisir le sous-ensemble de signaux qui représente le mieux le comportement du composant critique et de sa dégradation.
- Réduction de données : les signaux sélectionnés sont projetés dans un espace de dimension égale à un pour extraire la composante principale. Cette étape est réalisée à un instant t et répétée à intervalle régulier jusqu'à l'instant de fin de vie du composant critique. À un instant donné, la composante principale extraite correspond aux données projetées de l'intervalle $[0 \ t]$. Cette réduction/extraction est répétée sur tous les composants critiques.
- Extraction de tendances : pour chacune des composantes principales obtenue à l'instant t sur

chacun des composants critiques, on extrait le résidu en utilisant la technique EMD.

- Construction d’indicateurs de santé : pour chacun des résidus extraits, on calcule quatre caractéristiques : moyenne, variance, pente et point d’intersection du résidu avec l’axe des ordonnées. Chacune de ces caractéristiques est calculée à chaque instant t et les valeurs obtenues sont tracées dans le temps pour suivre l’évolution de l’état de santé du composant critique. Ces valeurs mises bout à bout sont appelées indicateurs de santé. On a ainsi quatre indicateurs de santé par composant critique.
- Base de modèles hors ligne : les indicateurs de santé générés pour tous les composants utilisés dans la phase d’apprentissage sont stockés dans une base de données. Cette dernière comporte autant de modèles que de composants critiques et chacun de ces modèles est représenté par quatre indicateurs de santé.

Phase en ligne

- Composant critique test : nouveau composant qui n’a pas été utilisé dans la phase hors ligne et pour lequel on cherche à estimer l’état de santé et à prédire le RUL.
- Signaux test : les mêmes types de signaux que ceux sélectionnés lors de phase hors ligne sont utilisés ici pour estimer l’état de santé du nouveau composant critique et prédire son RUL.
- Réduction de données, extraction de tendances et construction d’indicateurs de santé : la même démarche que celle utilisée dans la phase hors ligne est appliquée ici sur les signaux de surveillance sélectionnés. Le résultat de ces étapes est une matrice dans laquelle chaque vecteur ligne représente les valeurs des quatre indicateurs de santé à l’instant t du composant critique test.
- k-NN : le vecteur ligne contenant les valeurs des indicateurs à l’instant t est présenté à l’entrée de l’algorithme k-NN pour estimer sa classe d’appartenance. Cette classification se base sur la comparaison du vecteur obtenu en ligne avec les vecteurs étiquetés au même instant et stockés dans la base de modèles hors ligne. Si la probabilité de cette classification est supérieure à un seuil prédéfini, alors on retient le modèle proposé et on calcule le RUL du composant comme suit : $RUL(t) = EOL(\text{du cas le plus proche}) - t$. Sinon, on se sert du processus de Gauss pour la régression pour calculer le RUL : $RUL(t) = EOL(\text{de la valeur prédite par le GPR}) - t$. En résumé, le RUL du composant test est obtenu par une comparaison entre les observations courantes et celles sauvegardées dans la base de modèles.

3.1 Application aux turboréacteurs

Les données utilisées dans cette application sont fournies par le « NASA Prognostics Center of Excellence ». Elles sont obtenues par simulation d’un modèle de turboréacteur appelé C-MAPSS (Commercial Modular Aero-Propulsion System Simulation) [127]. Elles sont organisées en quatre fichiers d’apprentissage, quatre fichiers de test et quatre fichiers de valeurs de RUL. Les fichiers d’apprentissage contiennent des données capteurs relatives à différentes simulations sur différents turboréacteurs utilisés sous différentes conditions de fonctionnement et intégrant différents modes de défaillance. Chacune des simulations correspond à un historique de données allant de l’état neuf à l’état défaillant. Chaque turboréacteur fonctionne correctement puis subit à un instant donné une dégradation qui s’amplifie jusqu’à sa défaillance totale. Les fichiers de test ont été générés de la même façon. Cependant, les données contenues dans ces fichiers ne sont pas complètes, elles sont tronquées à partir de l’instant de déclenchement de la dégradation. Les fichiers RUL contiennent les durées réelles de fonctionnement avant défaillance des turboréacteurs test. Les fichiers d’apprentissage et de test contiennent chacun 26 colonnes représentant différentes variables. Les deux premières colonnes représentent le numéro du turboréacteur et le temps exprimé en nombre de cycles, les trois colonnes suivantes représentent les données de

fonctionnement et enfin, les 21 colonnes restantes représentent différents capteurs (température à l'entrée du turboréacteur, pression, vitesse de rotation, etc.).

Dans cette application le fichier de données « train_FD001.txt » est utilisé pour l'apprentissage et le fichier « test_FD001.txt » est utilisé pour le test. Chaque fichier contient des données relatives à 100 turboréacteurs. L'objectif est de prédire le nombre de cycles restants avant la défaillance (RUL) des turboréacteurs test. Les valeurs des RULs réels pour les données test se trouvent dans le fichier « RUL_FD001.txt. »

Sélection de variables : l'un des résultats de l'algorithme de sélection de variables est la paire de capteurs {8, 13}, c'est à dire la vitesse de rotation et la vitesse corrigée du turboréacteur (figure 4.19a). La paire sélectionnée est intéressante car les deux variables sont corrélées et sont liées à la vitesse du turboréacteur.

Indicateurs de santé : comme mentionné dans la description de l'approche (section 3), quatre indicateurs de santé (la pente, le point d'intersection de la courbe du résidu avec l'axe des ordonnées, la moyenne et la variance de la courbe du résidu) sont générés à chaque instant à partir de chaque résidu. Ces indicateurs sont ensuite labellisés avec une fin de vie correspondant à celle du turboréacteur utilisé, sauvegardés dans la base d'apprentissage hors ligne puis utilisés en ligne pour prédire les RULs des turboréacteurs test. La figure 4.19b montre un des quatre indicateurs de santé pour le turboréacteur numéro 61.

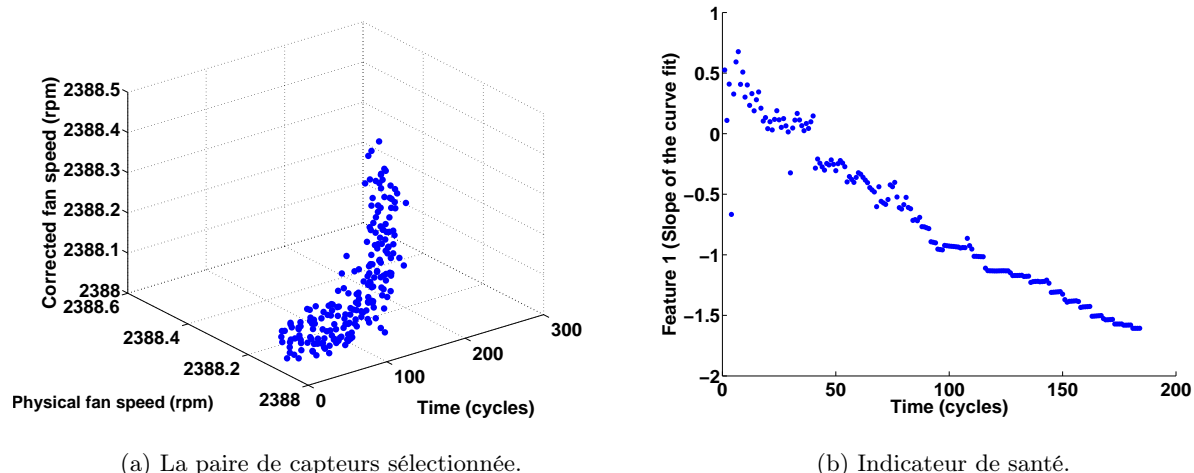




FIGURE 4.19: Résultat de la sélection de variables et exemple d'indicateur de santé obtenu pour le turboréacteur numéro 61.

Résultats d'estimation du RUL : la figure 4.20 montre le RUL estimé pour quatre turboréacteurs. On peut y constater que la précision des prédictions augmente avec le temps et que l'erreur de prédiction vers les derniers cycles est plus petite que celle en début des prédictions.


Pour évaluer la performance de la méthode proposée, nous avons calculé l'erreur moyenne absolue en pourcentage (mean absolute percentage error : MAPE) pour les 100 prédictions en ligne en




(a) RUL du turboréacteur 34.



(b) RUL du turboréacteur 41.



(c) RUL du turboréacteur 42.



(d) RUL du turboréacteur 81.

FIGURE 4.20: Résultats de prédiction des RULs pour les quatre turboréacteurs.

utilisant l'équation suivante :

$$MAPE(\%) = \frac{100\%}{n} \times \sum_{i=1}^n \left| \frac{RUL_i - RUL_i^*}{RUL_i} \right| \quad (4.20)$$

où RUL et RUL^* représentent les RULs réel et prédit et n le nombre total de prédictions. L'erreur calculée sur les derniers cycles des 100 turboréacteurs est égale à 12,19%. Elle est de 8,7691% sur les 15 premiers turboréacteurs.

3.2 Application aux batteries Lithium-Ion

Les données utilisées dans cette application sont collectées sur 34 batteries Lithium-Ion utilisées sous différentes conditions de fonctionnement à différentes températures [126]. Pour les besoins de simulation, seules les données liées à la charge et la décharge des batteries sont utilisées. Chaque ensemble de données, correspondant à une expérimentation, consiste en 11 variables telle que la tension de charge, le courant de charge, la température, la tension de décharge, le courant de décharge, la capacité, etc. Le vieillissement des batteries a été accéléré en les chargeant et déchargeant continuellement jusqu'à ce qu'elles soient complètement usées. Pour vérifier l'approche proposée, nous avons procédé à une validation croisée sur les données disponibles.

Ces dernières ont été divisées en trois groupes de tailles égales. Chaque groupe est ensuite divisé en données d'apprentissage et données test comme le montrent les tableaux 4.6 et 4.7. Dans la suite de cette application, seuls 31 ensembles de données correspondant à 31 batteries sont utilisés.

TABLE 4.6: Données d'apprentissage contenant trois lots.

Lot #1	Lot #2	Lot #3	EOL
B0006	B0005	B0005	168
B0007	B0007	B0006	168
B0026	B0025	B0025	28
B0027	B0026	B0026	28
B0028	B0027	B0028	28
B0030	B0029	B0029	40
B0031	B0031	B0030	40
B0032	B0032	B0031	40
B0034	B0033	B0033	197
B0036	B0036	B0034	197
B0039	B0038	B0038	47
B0040	B0040	B0039	47
B0043	B0042	B0042	112
B0044	B0044	B0043	112
B0045	B0045	B0045	72
B0047	B0046	B0046	72
B0048	B0048	B0047	72
B0050	B0049	B0049	25
B0051	B0050	B0050	25
B0052	B0051	B0052	25
B0055	B0054	B0054	102
B0056	B0056	B0055	102

TABLE 4.7: Données test contenant trois lots.

Lot #1	Lot #2	Lot #3	EOL
B0005	B0006	B0007	168
B0025	B0028	B0027	28
B0029	B0030	B0032	40
B0033	B0034	B0036	197
B0038	B0039	B0040	47
B0042	B0043	B0044	112
B0046	B0047	B0048	72
B0049	B0052	B0051	25
B0054	B0055	B0056	102

Sélection de variables : l'un des résultats de l'algorithme de sélection de variables est la paire de variables $\{6, 11\}$, c'est à dire la tension mesurée lors de la décharge de la batterie et la capacité de cette dernière (cf. figure 4.21a). Cette paire est intéressante car ces deux variables sont corrélées. En fait, la capacité est liée à l'état de santé de la batterie puisqu'une diminution de la capacité indique une dégradation de la batterie.

Indicateurs de santé : quatre indicateurs sont générés sur chaque résidu et à chaque instant. Ils sont ensuite labellisés avec la fin de vie correspondant à celle de la batterie utilisée,

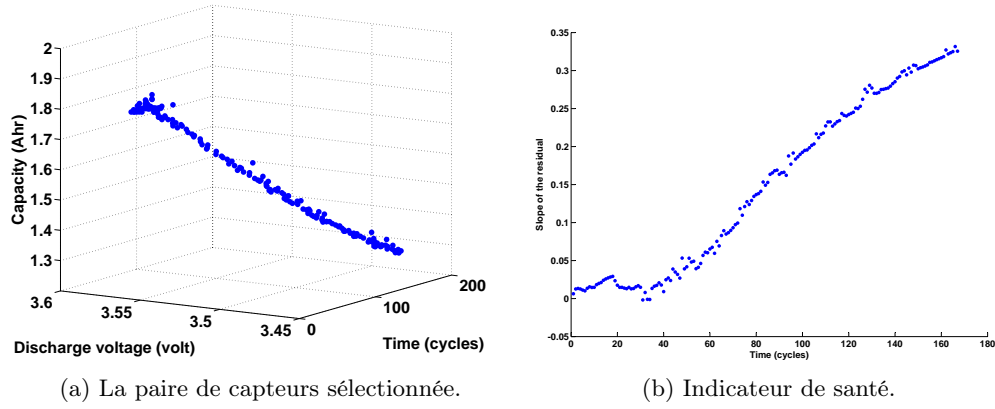


FIGURE 4.21: Résultat de la sélection de variables et exemple d'indicateur de santé obtenu pour la batterie B0005.

puis sauvegardés dans la base d'apprentissage hors ligne. La figure 4.21b montre un des quatre indicateurs de santé de la batterie B0005.

Résultats de prédiction du RUL : la figure 4.22 montre les RULs obtenus pour les batteries B0005 et B0025. Sur la figure 4.22a, on peut constater que la précision des prédictions augmente avec le temps. Sur la figure 4.22b, seuls 10 cycles ont été considérés comme des prédictions optimistes.

Pour évaluer la performance de l'approche proposée, nous avons calculé la MAPE sur les cycles de chaque batterie. La MAPE moyenne par lot est aussi calculée, elle est donnée par l'équation suivante :

$$MAPE_f = \frac{1}{n} \times \sum_{i=1}^n MAPE_{i,f} \quad (4.21)$$

où $MAPE_f$ est la MAPE moyenne pour un lot complet, $MAPE_{i,f}$ est la MAPE pour la batterie test i dans le lot f . Les résultats finaux sont calculés et résumés sur le tableau 4.8.

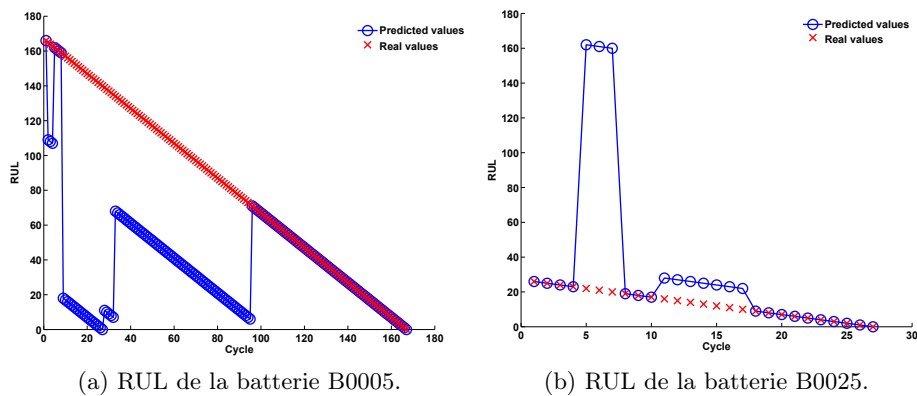


FIGURE 4.22: Résultats de prédiction du RUL pour 2 batteries.

Les résultats obtenus sur les deux types d'application, turboréacteur et batteries, montrent le caractère générique de l'approche proposée et son applicabilité sur des composants critiques mettant en jeu des phénomènes physiques différents. L'avantage de cette approche réside dans

TABLE 4.8: MAPE sur les trois lots de batteries.

Lot #1	Lot #2	Lot #3	Moyenne
28,0493%	26,3089%	28,3536%	27,5706%

le fait que les indicateurs de santé sont construits à partir de données résultant de la fusion de signaux jugés pertinents. Ces derniers sont identifiés en utilisant l'algorithme de sélection de variables proposé dans la section 4 du chapitre 2. Cela permet de générer des indicateurs de santé sensibles à la dégradation et de réduire les temps d'apprentissage et de test. L'étape de sélection de variables peut être également utilisée pour réduire le nombre de capteurs dans la phase de test (ou encore dans le PHM des nouvelles générations de composants) en ne gardant que les capteurs pertinents (ceux sélectionnés dans la phase d'apprentissage). Cela permettrait de réduire les coûts de mise en œuvre et de proposer des solutions de PHM compétitives.

4 Approche utilisant les SVRs

Cette approche repose sur deux phases : une phase hors ligne pour apprendre les modèles de dégradation et une phase en ligne pour estimer l'état de santé du composant et prédire son RUL. Les étapes de chacune de ces phases sont montrées sur le synoptique global donné sur la figure 4.23. Ces étapes sont expliquées dans les deux sous-sections suivantes.

4.1 Phase hors ligne

1. Ensemble de composants critiques pour l'apprentissage : ce sont les composants dont la dégradation a été accélérée pour obtenir des historiques de données représentatifs des dégradations.
2. Signaux bruts : ils peuvent être de différents types (vibration, température, etc.).
3. Filtrage : cette étape consiste à extraire la composante qui caractérise la dégradation du composant critique. Elle est réalisée en utilisant la décomposition modale empirique (EMD). Pour rappel, l'EMD permet de décomposer le signal en fonctions modales intrinsèques dont chacune représente le signal d'entrée dans une bande de fréquence bien spécifique.
4. Extraction d'indicateurs de santé (HIs) : la transformée de Hilbert est appliquée sur les IMFs sélectionnées (celles qui contiennent les fréquences caractéristiques des défauts). Cette transformée permet d'extraire les fréquences instantanées ainsi que les amplitudes instantanées de chaque IMF sélectionnée. Les informations extraites servent ensuite à construire des indicateurs de santé représentés par des densités spectrales de Hilbert localisées sur les fréquences des défauts.
5. Constitution d'une base de données : cette base regroupe les historiques de dégradation pour plusieurs composants critiques (exemple : roulements), chacun ayant sa durée de vie propre.
6. Extraction d'un ensemble de séries temporelles pour l'apprentissage : plusieurs séries temporelles, dont la longueur de chacune est fixe, sont extraites à partir de l'historique de chaque composant critique. L'ensemble des séries est ensuite mis dans une matrice et utilisé pour l'apprentissage des modèles SVRs. Les détails de la construction de cette matrice

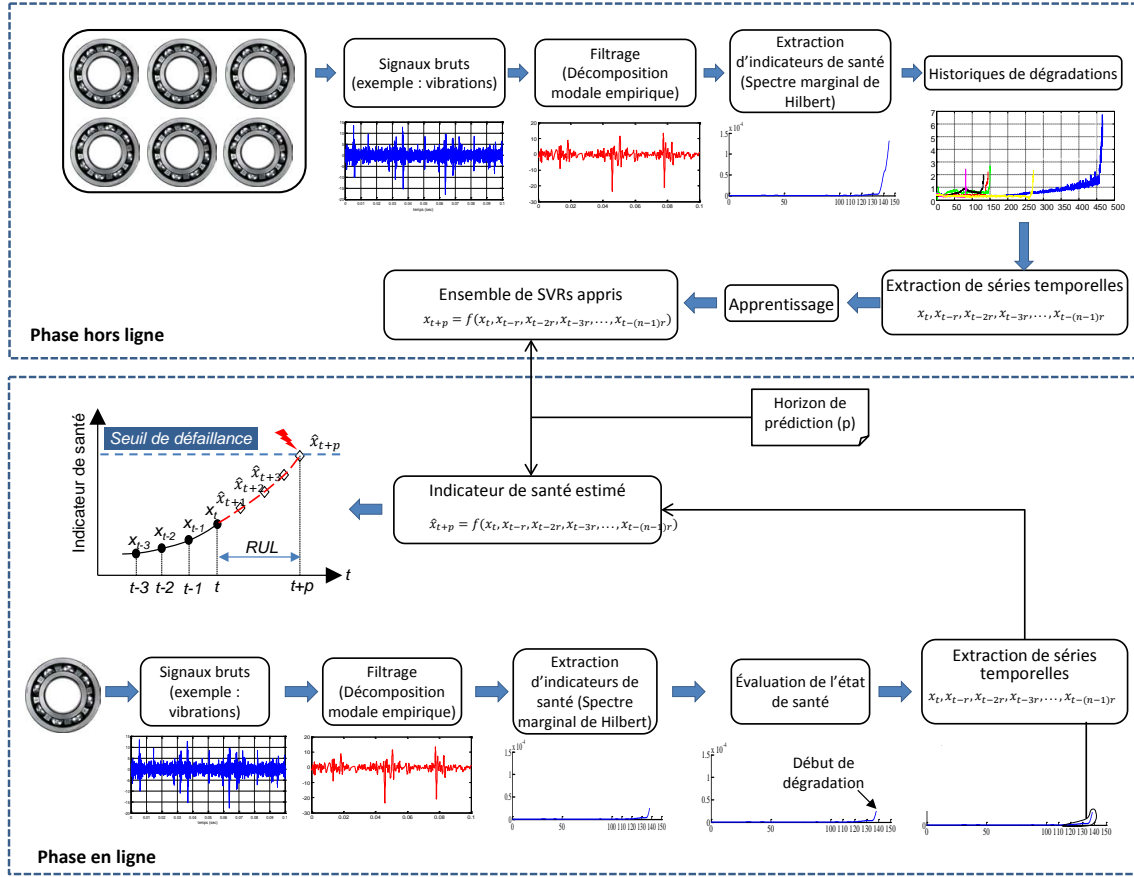


FIGURE 4.23: Approche de pronostic basée sur les SVRs.

sont donnés dans le paragraphe suivant la description de ces deux phases hors ligne et en ligne.

7. Construction des modèles SVRs : ces derniers sont construits en fonction des horizons de prédiction et en utilisant la matrice d'apprentissage obtenue dans l'étape précédente.

4.2 Phase en ligne

1. Nouveau composant critique pour le test : composant utilisé pour estimer son état de santé et prédire son RUL.
2. Signaux bruts, EMD et HHT : les mêmes étapes 2 à 4 de la phase hors ligne.
3. Évaluation de l'état de santé : cette étape consiste à détecter un début de dégradation en utilisant différentes méthodes de détection automatique de défaillances (dépassement de seuils, apprentissage automatique, etc.).
4. Extraction de la série temporelle : elle consiste à définir la longueur $(n - 1)$ de la série temporelle et le pas d'observation r (espacement entre les observations). La longueur de la série temporelle doit être identique à celle utilisée lors de la phase d'apprentissage.
5. Définir la valeur de l'horizon de prédiction : cette valeur est nécessaire pour la prédiction du RUL.

6. Estimation des indicateurs de santé : elle consiste à utiliser le modèle SVR correspondant (choisi selon l'horizon de prédiction défini à l'étape précédente) sur la série temporelle test. Les valeurs prédites de chaque indicateur de santé sont ensuite tracées dans le temps.
7. Estimation du RUL : la valeur du RUL est obtenue par l'intersection de l'indicateur de santé avec un seuil de défaillance préalablement défini.

La construction de la matrice d'apprentissage et des SVRs correspondants ainsi que l'estimation du RUL sont résumés sur le schéma de la figure 4.24.

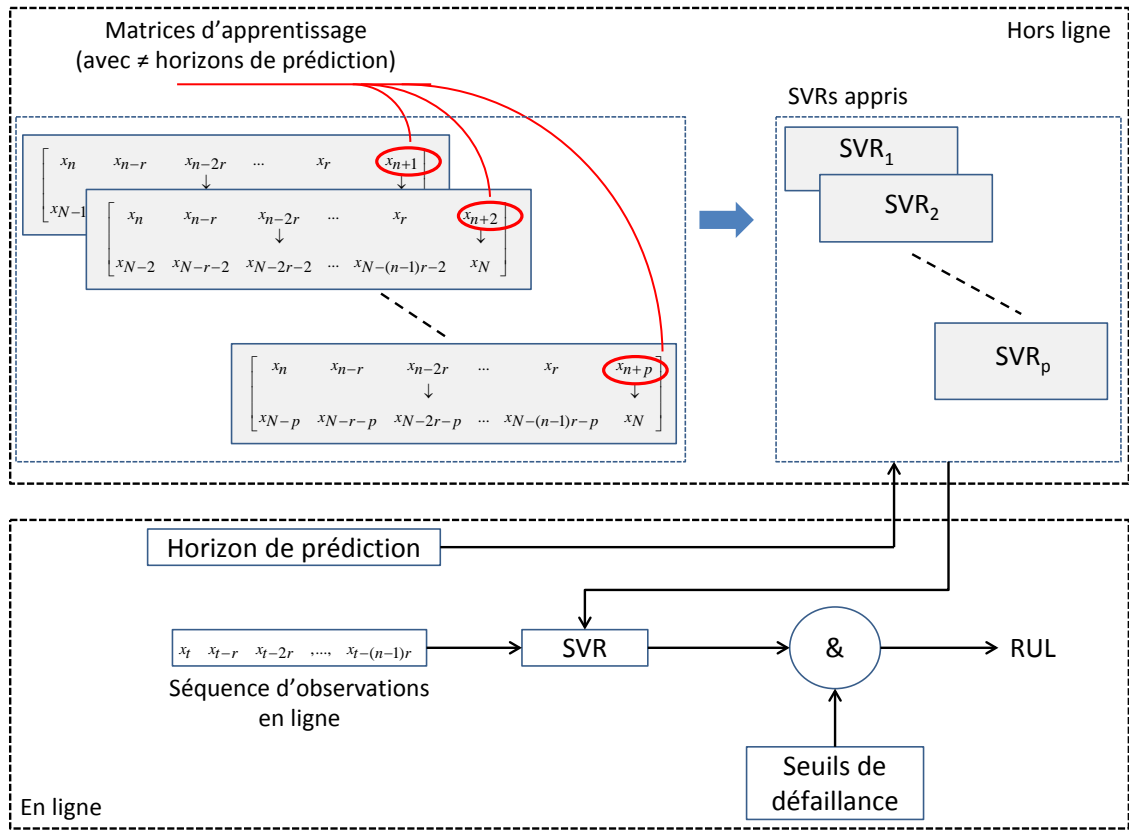


FIGURE 4.24: Apprentissage des modèles SVRs et estimation du RUL.

Sur cette figure, chaque matrice d'apprentissage pour un horizon de prédiction $n + 1$

$$\begin{bmatrix} x_n & x_{n-r} & x_{n-2r} & \dots & x_r & x_{n+1} \\ & & \downarrow & & & \downarrow \\ x_{N-1} & x_{N-r-1} & x_{N-2r-1} & \dots & x_{N-(n-1)r-1} & x_N \end{bmatrix} \quad (4.22)$$

est construite comme suit :

$$\begin{bmatrix}
 \begin{array}{c} \text{Composant 1} \\ \downarrow \\ \text{Composant 2} \\ \downarrow \\ \text{Composant } M \end{array} &
 \begin{array}{cccccc}
 x_n^1 & x_{n-r}^1 & x_{n-2r}^1 & \dots & x_r^1 & x_{n+1}^1 \\
 \downarrow & & \downarrow & & & \downarrow \\
 x_{L_1-1}^1 & x_{L_1-r-1}^1 & x_{L_1-2r-1}^1 & \dots & x_{L_1-(n-1)r-1}^1 & x_{L_1}^1 \\
 \\
 x_n^2 & x_{n-r}^2 & x_{n-2r}^2 & \dots & x_r^2 & x_{n+1}^2 \\
 \downarrow & & \downarrow & & & \downarrow \\
 x_{L_2-1}^2 & x_{L_2-r-1}^2 & x_{L_2-2r-1}^2 & \dots & x_{L_2-(n-1)r-1}^2 & x_{L_2}^2 \\
 \\
 x_n^M & x_{n-r}^M & x_{n-2r}^M & \dots & x_r^M & x_{n+1}^M \\
 \downarrow & & \downarrow & & & \downarrow \\
 x_{L_M-1}^M & x_{L_M-r-1}^M & x_{L_M-2r-1}^M & \dots & x_{L_M-(n-1)r-1}^M & x_{L_M}^M
 \end{array}
 \end{bmatrix} \quad (4.23)$$

On construit ainsi autant de matrices (et donc de SVRs) que d'horizons de prédiction. On a donc p matrices d'apprentissage correspondant à p horizons de prédictions. Chaque matrice donnera lieu à un SVR. Chaque ligne de la matrice d'apprentissage comprend une série temporelle (nombre d'observations) et un horizon de prédiction (dernière valeur de chaque ligne). Dans cette matrice :

- $n - 1$ est la longueur de la série temporelle (nombre d'observations qui compose la série temporelle), sans la dernière colonne qui correspond à l'horizon de prédiction ;
- r est le pas d'observation, il représente l'espacement entre les observations au sein de chaque série temporelle ;
- N est le nombre de séries temporelles utilisées dans la matrice d'apprentissage (nombre de lignes de la matrice) ;
- L_i , avec i allant de 1 à M , représente le nombre de séries temporelles prises sur chaque historique de données (correspondant à chaque composant critique). On a donc : $N = L_1 + L_2 + \dots + L_M$;
- M est le nombre de composants critiques considérés dans la phase d'apprentissage.

Exemple :

Pour trois historiques de données d'horizons temporels différents correspondants à trois roulements, on considère trois observations pour chaque série temporelle et on prend 50 séries temporelles pour le premier roulement, 70 pour le deuxième roulement et 100 pour le troisième roulement. On considère également quinze horizons de prédiction. On obtient alors quinze matrices d'apprentissage, chacune ayant 220 lignes et 4 colonnes (la dernière colonne représente l'horizon de prédiction). Ces 15 matrices donneront lieu à 15 modèles SVRs.

4.3 Application

L'approche décrite dans la section précédente a été appliquée sur des données issues de trois roulements de type NSK 6804RS. Lors des tests, la vitesse de rotation du moteur et la charge appliquée aux roulements ont été fixées respectivement à 1800 tr/min et 4000 N. Les paramètres géométriques des trois roulements sont données sur le tableau 4.9.

Extraction d'indicateurs de santé

Afin d'évaluer l'état de santé courant des roulements et prédire leur RUL, nous avons dans un premier temps calculé les fréquences caractéristiques correspondant aux trois types de défaillance : fréquence de la bague interne $f_{ir} = 221$ Hz, fréquence de la bague externe $f_{or} =$

TABLE 4.9: Caractéristiques des roulements utilisés.

Diamètre des billes (mm)	3,5
Nombre de billes	13
Diamètre de la bague externe (mm)	29,1
Diamètre de la bague interne (mm)	22,1
Diamètre moyen du roulement (mm)	25,6

168 Hz et fréquence des billes $f_b = 215,48$ Hz. Ces fréquences ont pu être calculées grâce aux données géométriques des roulements utilisés (tableau 4.9). Ensuite, nous avons fait appel à la transformée de Hilbert-Huang pour extraire trois indicateurs de santé $h_i(f_{or})$, $h_i(f_{ir})$ et $h_i(f_b)$ à partir des signaux vibratoires issus de l'accéléromètre placé sur l'axe horizontal. Ces indicateurs, qui correspondent aux densités spectrales de Hilbert autour des trois fréquences caractéristiques, permettent de suivre l'évolution de la dégradation des éléments constitutants des roulements. Les figures 4.25-(a), 4.25-(b), 4.25-(c) et 4.25-(d) montrent l'évolution des trois indicateurs de santé (bague externe, bague interne et billes) ainsi que le RMS du roulement numéro 4. On peut y constater que les premiers signes de vieillissement commencent à apparaître au niveau des billes après 114 minutes de test. Ensuite, à partir de 116 minutes de test d'autres signes de dégradation sont observés au niveau des billes et de la bague interne. Enfin, après 112 minutes les troisièmes signes de dégradation sont observés sur les trois éléments (billes, bagues interne et externe). Cependant, sur le RMS, les premiers signes de dégradation commencent à apparaître seulement après 138 minutes de test. Ces résultats montrent l'efficacité des indicateurs temps-fréquence par rapport à un indicateur purement temporel.




FIGURE 4.25: Évolution des indicateurs de santé en fonction de la dégradation du roulement numéro 4.

Évaluation de l'état de santé des roulements

Cette étape est réalisée en combinant les trois indicateurs $h_i(f_{or})$, $h_i(f_{ir})$ et $h_i(f_b)$. Cela permet de construire un espace de représentation (figure 4.26) dans lequel la variable temps n'apparaît pas et sur lequel il est possible d'isoler les différents états de santé (sous forme de classes) de

chaque roulement. Sur la figure 4.26 on peut constater trois états de dégradation représentés par trois classes Ω_1 , Ω_2 et Ω_3 . La première classe Ω_1 représente l'état normal du roulement, la deuxième Ω_2 correspond à un début de dégradation du roulement et enfin la troisième Ω_3 concerne la progression de la dégradation du roulement.




FIGURE 4.26: États de dégradation du roulement numéro 4.

Les classes identifiées sur la figure 4.26 ainsi que les valeurs des indicateurs de chaque classe sont utilisés pour apprendre les paramètres de trois SVMs (un SVM par classe). Ces SVMs sont ensuite exploités pour affecter en ligne les nouvelles valeurs des trois indicateurs à l'une des trois classes et évaluer l'état des roulements 1 à 3 (figure 4.27).




FIGURE 4.27: Détection de l'état de dégradation des roulements 1 à 3.

Pronostic de défaillances

Pour estimer la durée de fonctionnement avant défaillance des trois roulements, nous avons construit trois SVRs, un par roulement. La fonction noyau utilisée est une Gaussienne de paramètre $r = 6$ minutes. La longueur $(n - 1)$ des séries temporelles est égale à quatre et l'horizon de prédiction est variable. Il va de T_s à $k.T_s$ où k est un entier, T_s un pas de prédiction égal à 10 secondes et $k.T_s$ correspond à l'instant où le roulement est considéré comme défaillant. Le seuil de défaillance de chaque roulement a été obtenu à partir de sa classe Ω_3 . En outre, pour chacun des roulements, nous avons calculé trois RULs (RUL_{or} , RUL_{ir} et RUL_b) correspondant aux trois éléments constitutifs (bague externe, bague interne et billes). Le RUL_{or} de la bague externe est obtenu pour un seuil de défaillance égal à $8,9 \times 10^{-5}$ Watt, le RUL_b des billes pour un seuil de dégradation égal à $1,35 \times 10^{-4}$ Watt et le RUL_{ir} de la bague interne pour un seuil de dégradation égal à $1,31 \times 10^{-4}$ Watt.

Les figures 4.28-(a), 4.28-(b) et 4.28-(c) montrent les résultats des trois RULs pour le roulement numéro 1. Nous rappelons que le calcul du RUL n'est pas réalisé dès les premiers instants de fonctionnement du roulement, mais plutôt après avoir constaté et détecté un début de dégradation. Les résultats complets des RULs obtenus pour les roulements 1, 2 et 3 en utilisant les SVRs




FIGURE 4.28: Estimation des RULs des éléments constitutifs du roulement 1.

TABLE 4.10: Résultats des RULs estimés pour les roulements 1 à 3.

	Roulement 1	Roulement 2	Roulement 3
RUL_1 (min)	6,8	2	1,5
RUL_2 (min)	7,3	4,3	1,2
RUL_3 (min)	7,1	3,8	1,2
RUL estimé (min)	6,8	2	1,2
E_r (%)	0,6	1,1	1,25

appris ainsi que les erreurs de prédiction (E_r %) correspondantes sont donnés sur le tableau 4.10. L'erreur de prédiction est exprimée par la relation suivante :

$$E_r (\%) = 100 \times \left| \frac{t_{failure} - \hat{t}_{failure}}{t_{failure}} \right| \quad (4.24)$$

où $t_{failure}$ et $\hat{t}_{failure}$ correspondent respectivement aux instants réel et estimé de défaillance pour le roulement testé.

L'approche proposée dans cette section est particulièrement adaptée aux données non stationnaires issues de phénomènes physiques oscillatoires. Elle a été appliquée sur des signaux vibratoires issus de roulements, mais peut être généralisée sur d'autres composants, notamment les engrenages, en considérant d'autres types de signaux comme par exemple les émissions acoustiques. Les indicateurs de santé utilisés sont générés au moyen de la transformée de Hilbert-Huang. Cette dernière permet de réaliser une analyse temps-fréquence très fine et de construire des indicateurs de santé capables de suivre dans le temps les amplitudes des signatures fréquentielles des éléments constituant les composants critiques (roulements dans le cas de l'application présentée dans cette section). Une des caractéristiques de l'approche proposée réside dans le fait que le pronostic n'est pas lancé dès les premiers instants de l'utilisation du composant critique, mais plutôt à partir de l'instant où on détecte un début de dégradation.

5 Conclusion

Dans ce chapitre nous avons abordé la problématique globale de l'estimation de la durée de fonctionnement avant défaillance (RUL) du composant critique. Pour la résoudre, nous avons travaillé sur trois problématiques : 1) l'évaluation de l'état de santé courant du composant, 2) la prédiction de son état futur et 3) le calcul de son RUL.

L'évaluation de l'état courant et la prédiction de l'état futur reposent sur l'exploitation de modèles de comportement en lien avec la progression de la dégradation du composant. Ces modèles, un par condition de fonctionnement, sont appris hors ligne à partir de matrices de caractéristiques ou d'indicateurs de santé obtenus sur un échantillon représentatif de composants de même référence. Ensuite, dans la phase en ligne, les observations courantes sont continuellement injectées dans les modèles appris pour sélectionner celui qui représente le mieux le comportement du composant test. Le modèle sélectionné est utilisé pour estimer à tout instant l'état de santé du composant et prédire son état futur. Nous avons ainsi montré que la qualité de l'estimation de l'état courant et de la prédiction de l'état futur dépendent fortement de la qualité des modèles de dégradation utilisés.

Les seuils de défaillance jouent un rôle important dans la prédiction du RUL. En effet, ce dernier résulte de l'intersection de la prédiction de l'état futur du composant et de son seuil de défaillance. Ainsi, des valeurs de seuils erronées ou mal choisies conduisent à des valeurs erronées du RUL. Dans les approches que nous avons présentées, les valeurs des seuils ont été considérées constantes et définies expérimentalement en fonction des limites de fonctionnement du composant. Ces limites sont déterminées selon divers critères : niveau de vibration, qualité d'usinage, niveau du bruit sonore, etc. Cependant, dans la pratique, les seuils peuvent être variables selon le composant étudié. Ils doivent donc être choisis en conséquence.

Les approches proposées dans ce chapitre traitent de la problématique globale du pronostic de défaillances. Elles font appel à des outils de modélisation puissants et adaptés aux données qui caractérisent les dégradations des composants critiques. Elles considèrent aussi bien des données multi-dimensionnelle (matrice de caractéristiques) que des données mono-dimensionnelle (indicateurs de santé). Elles ont été appliquées sur différentes classes de composants (roulements, batteries, turboréacteurs et outils de coupe) pour montrer leur efficacité et leur applicabilité. De part leur aspect générique, elles peuvent être généralisées à d'autres types de composants que ceux abordés dans ce mémoire.

L'estimation de l'état courant (health assessment) et le pronostic de défaillances (calcul du RUL) constituent les étapes finales de la démarche développée dans ce mémoire. Elles consistent à exécuter les modèles construits dans le chapitre précédent et à continuellement comparer leurs sorties à des seuils de défaillance. Ainsi, l'une des difficultés majeures du calcul du RUL réside dans la définition des seuils. En effet, si le modèle de dégradation est validé, le RUL correspond à l'intervalle de temps qui sépare l'instant courant de l'instant où la sortie du modèle coïncide avec le seuil. Dans la pratique, les seuils sont dynamiques et varient en fonction du composant étudié, des conditions de fonctionnement et du contexte d'utilisation. Pour les déterminer, l'une des pistes serait de recourir à une approche adaptative faisant appel à des méthodes d'apprentissage automatique.

Ce chapitre clôt l'ensemble de nos contributions et ouvre la voie aux perspectives de recherche qui seront présentées dans le chapitre suivant.

Conclusions et perspectives

1 Conclusions

Pour développer l’approche de pronostic guidée par les données, nous nous sommes focalisés sur les composants critiques de systèmes industriels.

Le choix des composants critiques et l’acquisition de données représentatives de l’initiation et de la progression des dégradations ont constitué la première problématique de notre processus de pronostic. Dans ce cadre, nous avons proposé une démarche rationnelle permettant d’isoler les composants critiques, de définir les grandeurs physiques à surveiller, de choisir les capteurs, de définir les tests de vieillissement accéléré et de spécifier le système d’acquisition et de stockage des données. Cette démarche qui relève du domaine de l’ingénierie, nécessite des compétences et des connaissances pluridisciplinaires de part la nature des phénomènes physiques qui sont mis en jeu dans les systèmes industriels. C’est aussi une démarche qui doit être réalisée en étroite collaboration avec le constructeur et/ou l’exploitant du système étudié car ils disposent des spécifications techniques et de l’expertise nécessaires à la réussite de la démarche.

La deuxième problématique à laquelle nous nous sommes attaqués concerne le traitement des données de surveillance afin d’extraire des informations pertinentes permettant de révéler les dégradations et de suivre leur progression dans le temps. Pour cela, nous avons proposé une palette de techniques, issues pour la plupart du domaine du traitement du signal, pour extraire, dans un premier temps, des caractéristiques représentatives des dégradations constatées. Ces caractéristiques couvrent les trois domaines temporel, fréquentiel et temps-fréquence. Ensuite, nous avons proposé des méthodes de sélection et de réduction afin de mieux visualiser, analyser et interpréter les caractéristiques. Enfin, nous avons proposé une démarche de construction d’indicateurs de santé permettant de regrouper dans un même signal l’évolution de l’état de santé du composant critique. L’extraction de caractéristiques et la construction d’indicateurs de santé pertinents nécessitent des connaissances sur les mécanismes de dégradation. Ces connaissances permettent de mieux cibler les informations à extraire des signaux bruts en fonction des composants étudiés et des phénomènes de dégradation mis en jeu et d’éviter ainsi de fausses estimations ou prédictions. En effet, les caractéristiques utilisées pour des défauts de roulements pourraient ne pas avoir la même pertinence que celles utilisées pour la dégradation de batteries par exemple.

La troisième problématique de nos travaux de recherche concerne la modélisation de la dégradation. Pour la résoudre, nous avons proposé d’utiliser une boîte à outils composée des réseaux Bayésiens dynamiques et de modèles de régression non linéaires (SVR et GPR). Ces outils, issus du domaine de l’intelligence artificielle, généralisent des outils recensés et utilisés dans l’approche guidée par les données. D’un côté, les RBDs généralisent les chaînes de Markov cachées (HMMs) et les filtres de Kalman. De l’autre côté, les SVRs et le GPR s’avèrent plus performants que

les régressions linéaires ou non linéaires classiques. Ces outils ont été choisis pour leur capacité à modéliser les incertitudes des données et à prendre en compte les non linéarités et l'aspect stochastique des dégradations.

Enfin, la quatrième problématique est liée à l'évaluation de l'état de santé des composants et l'estimation de leurs durées de fonctionnement avant défaillance. Nous avons proposé trois contributions majeures, sous forme d'approches, chacune reposant sur un ou plusieurs outils de modélisation. Les trois approches proposées reposent toutes sur deux phases : une première phase d'apprentissage réalisée hors ligne et une seconde phase d'exploitation (ou de test) réalisée en ligne. Le but de la première phase est de générer des modèles de dégradation tandis que celui de la seconde phase est d'évaluer l'état de santé des composants et prédire leurs RULs. La première approche utilise les RBDs pour modéliser la dégradation à partir d'une matrice de caractéristiques extraites des données de surveillance. C'est une approche probabiliste/stochastique qui permet de modéliser les stades de dégradation du composant et les représenter sous forme d'états. C'est donc une démarche intuitive et facilement compréhensible par des industriels. La deuxième approche est basée sur l'intégration des outils kNN (k-plus proches voisins) et GPR et elle est appliquée sur les indicateurs de santé. À la différence de l'approche précédente où l'état courant et le RUL sont obtenus en simulant le RBD du composant, dans cette approche, l'état de santé et le RUL sont obtenus directement en comparant l'indicateur de santé courant à des indicateurs de santé générés dans la phase d'apprentissage. Enfin, la troisième approche fait appel aux SVRs et est également appliquée sur les indicateurs de santé. Elle permet de modéliser ces derniers par des modèles de régression non linéaires et d'avoir ainsi des modèles proches du comportement de la dégradation.

Les contributions que nous avons apportées ont été appliquées sur des données issues de différents types de composants critiques : roulements à billes, batteries, turboréacteurs et outils de coupe, ce qui a permis de montrer leur efficacité et applicabilité.

2 Perspectives

En dépit des résultats satisfaisants que nous avons obtenus, des pistes de recherche et applicatives restent à explorer. Elles concernent la prise en compte des interventions de maintenance durant la durée de vie du composant, l'utilisation des données d'exploitation, la prise en compte du contexte d'utilisation, la modélisation des interactions entre composants, le changement d'échelle pour passer de macro-systèmes aux micro-systèmes et la capitalisation et valorisation des compétences acquises dans le domaine du PHM. Ces pistes peuvent être regroupées dans quatre principales perspectives que nous envisageons de développer dans nos futurs travaux. Il s'agit : 1) de la généralisation de la démarche développée aux systèmes complexes, 2) du développement et de la consolidation du PHM des micro-systèmes en particuliers des MEMS (Micro-Electro-Mechanical Systems), 3) du développement d'algorithmes d'aide à la décision et 4) des transferts industriel et académique.

2.1 Pronostic de défaillances de systèmes complexes

Dans les travaux présentés dans ce mémoire nous nous sommes intéressés au pronostic de défaillances de composants critiques pris individuellement dans un système industriel. Cette approche, dont nous avons montré l'efficacité, repose sur l'hypothèse que les composants sont indépendants les uns des autres et que le RUL du système correspond au plus pessimiste de tous

les RULs (composant dont le RUL est le plus petit). Cependant, dans la pratique ces hypothèses sont très fortes et la réalité n'est pas aussi simple. En effet, un système industriel est formé par des sous-systèmes, eux-mêmes constitués de composants, chacun remplissant une fonction donnée et possédant des connexions physiques ou fonctionnelles avec ses voisins. On a ainsi des composants interconnectés et interdépendants. Dans ce cas, une approche globale de pronostic de défaillances sur le système complet est nécessaire et doit prendre en compte différents aspects. Ces derniers concernent l'interdépendance des composants, la diversité des phénomènes de dégradation à surveiller et modéliser, les paramètres ou grandeurs physiques à mesurer, le choix et le placement des capteurs, l'utilisation des données d'exploitation et de celles du retour d'expérience, le contexte dans lequel évolue le système et les interventions de maintenance. Ces aspects peuvent être regroupés dans trois volets et constituent une partie des futurs travaux de recherche que nous envisageons de mener sur les systèmes complexes : 1) les données nécessaires au pronostic, 2) la modélisation des phénomènes de dégradation et 3) la prédiction du RUL du système. Ces développements s'inscrivent dans la continuité de nos travaux actuels, mais à l'échelle du système global.

Le premier volet concerne la collecte de données pertinentes et représentatives des interactions entre composants, des mécanismes de dégradation (leur déclenchement et leur évolution) et des défaillances qui peuvent survenir dans le système. Pour ce volet, nous avons identifié trois verrous : la compréhension des mécanismes de dégradation des composants, la corrélation entre les dégradations et l'identification des paramètres physiques à surveiller. Pour lever ces verrous, nous avons besoin d'exploiter l'architecture fonctionnelle du système, d'utiliser les connaissances fournies par les experts et d'analyser les données du retour d'expérience. Cela nous permettra de révéler des informations pertinentes sur la fiabilité des composants constituant le système, de mieux comprendre leurs mécanismes de dégradation et leurs facteurs de déclenchement, d'identifier pour chaque composant les paramètres physiques sensibles aux dégradations et de choisir les capteurs et leur emplacement optimal en tenant compte de différents facteurs tel que l'encombrement et l'accessibilité aux grandeurs physiques à surveiller. Concernant les capteurs, nous avons considéré dans ce mémoire qu'ils sont filaires et indépendants les uns des autres. Nous avons également supposé qu'ils sont tout le temps disponibles et sans défaillances, ce qui n'est pas toujours le cas dans la pratique. Pour alléger ces hypothèses, et pour assurer la continuité des données de surveillance, nous proposons d'intégrer des réseaux de capteurs sans fils. Ces derniers offrent deux avantages : 1) ils permettent d'assurer la continuité des données grâce la topologie du réseau, à la redondance de capteurs et à la tolérance aux fautes, et 2) ils permettent dans certaines applications de gagner en poids (technologie sans fils, capteurs miniatures, etc.) et de proposer ainsi des solutions de PHM compétitives.

Le deuxième volet traite de la modélisation des dégradations. Il constitue en lui-même le verrou principal que nous envisageons de lever. En plus des données de surveillance, cette modélisation nécessite la prise en compte des conditions d'exploitation du système (profils de fonctionnement, conditions environnementales, facteurs humains, etc.) et des actions de maintenance qui peuvent être effectuées durant le fonctionnement du système. La modélisation doit également représenter les interactions entre les différents mécanismes de dégradation et leurs vitesses de progression et de propagation. En effet, dans le cas de plusieurs composants sollicités différemment, même si plusieurs dégradations se déclenchent au même instant, leur progression peut prendre différentes trajectoires avec différentes vitesses. C'est donc un processus complexe qui se met en place et qu'il faudra modéliser. Par ailleurs, une réparation d'un ou de plusieurs composants modifie l'état du système et par conséquent le modèle doit être actualisé. L'une de nos futures contributions consistera alors à construire des modèles fidèles au comportement du système, exploitables par l'utilisateur et offrant un meilleur compromis entre précision et

complexité. Ces modèles peuvent être construits par la combinaison de plusieurs sous-modèles, chacun pouvant être obtenu en utilisant un outil adapté (équations algébro-différentielles, ensemble de règles, régressions, classifications, etc.). Les outils de modélisation seront choisis en fonction de la complexité des phénomènes à modéliser, des données disponibles et de la précision du modèle souhaité. Pour cela, l'approche hybride, combinant l'approche guidée par les données et l'approche basée sur un modèle physique, semble davantage adaptée.

Enfin, le troisième volet sera consacré à la prédiction du RUL du système. Cette prédiction doit être la plus exacte et la plus précise possible. Pour l'obtenir, nous devons intégrer au processus de pronostic les tâches de détection des anomalies et de diagnostic de défaillances. En effet, pour prédire le RUL, nous avons besoin de connaître l'état courant du système et par conséquent, l'état courant de ses composants. Dans le cas du fonctionnement nominal du système (absence d'anomalie ou de défaillances) il n'y a pas lieu de lancer le pronostic. Ce dernier doit être activé seulement en cas de dégradations et/ou de défaillances avérées et dont le résultat est donné par les modules de détection et de diagnostic. Ainsi, pour ce volet, nous avons identifié deux verrous potentiels : le premier concerne la détection à temps du déclenchement d'une ou de plusieurs dégradations et leur rôle sur l'état des autres composants, et le second est lié à la définition de seuils de défaillances. Concernant la détection du déclenchement des dégradations, des méthodes quantitatives (relations de redondance analytique, résidus, estimations paramétriques, observateurs, etc.) pourront être utilisées. Dans ce domaine, nous possédons une certaine expertise acquise durant nos travaux de thèse et que nous envisageons de mettre à profit. Ces méthodes pourront être complétées par des méthodes qualitatives (apprentissage automatique, ensemble de règles, etc.). Le second verrou à lever concerne la définition de seuils d'alarmes (ou de défaillances). Les seuils ont une importance capitale dans la prédiction du RUL puisqu'une valeur erronée du seuil conduit à un RUL différent du RUL réel. Ils doivent également être variables en fonction du système, de ses conditions d'utilisation et des exigences de performance et de sécurité imposées par l'exploitant. Ils peuvent être déterminés en utilisant différentes méthodes : estimation de densités de probabilité à partir de tests expérimentaux, utilisation des connaissances expertes, apprentissage automatique sur des données d'exploitation et de retour d'expérience, etc.

2.2 Pronostic de défaillances des MEMS

Un MEMS, acronyme anglais de Micro-Electro-Mechanical System, est un système intégrant des éléments mécaniques, optiques, électromagnétiques, thermiques et fluidiques et utilisant l'électricité comme source d'énergie en vue de réaliser des fonctions de mesure et/ou d'actionnement dans une structure présentant des dimensions micrométriques. Les MEMS se présentent sous différentes catégories (micro-capteurs, micro-actionneurs, radio-frequency MEMS, etc.) et sont largement répandus et utilisés dans des applications telle que l'automobile, les télécommunications, l'aérospatial, le biomédical et l'optique. Ils font ainsi partie de notre vie quotidienne et leurs défaillances peuvent avoir des répercussions négatives sur la disponibilité et la fiabilité des systèmes dans lesquels ils sont utilisés et/ou sur notre confort, notre productivité ou notre sécurité.

Il y a maintenant un an, nous avons initié la thématique PHM des MEMS au sein de notre laboratoire de recherche. C'est donc une thématique récente que nous développons et consolidons et sur laquelle nous avons fait soutenir deux Masters 2 Recherche et avons actuellement un doctorant. Notre objectif est de développer le PHM des micro-systèmes en s'appuyant sur les connaissances et compétences que nous avons acquises dans le domaine des macro-systèmes. Cependant, conscients des spécificités du micro-monde, nous avons dans un premier temps commencé par l'explorer pour comprendre ces systèmes : architectures, fonctionnement, mécanismes

de dégradation, facteurs d'influence et de déclenchement (température, humidité, vibration, bruit, poussière, chocs, surcharges électriques, mécaniques, thermiques, etc.), instrumentation, etc. Le développement et la consolidation de cette thématique nécessitent la mise en place de nouvelles méthodes de PHM. Ces méthodes peuvent être inspirées de celles développées dans le cas des macro-systèmes. Néanmoins, il est nécessaire de tenir compte des spécificités des MEMS que sont la miniaturisation, les bruits, l'encombrement et la sensibilité aux conditions d'utilisation. Au terme de cette première étape, nous avons établi une première synthèse qui nous a permis de comprendre une partie des points énoncés précédemment. Il en ressort également que la majeure partie des travaux publiés dans la littérature scientifique dans ce domaine traite de la fiabilité des MEMS. Or, la fiabilité est définie comme « l'aptitude d'un dispositif à accomplir une fonction requise dans des conditions données pour une période de temps donnée ». Elle a pour but de fournir des modèles de durée de vie prévisionnels obtenus sur une population de composants. L'inconvénient de cette démarche réside dans le fait qu'une fois les modèles de durée de vie sont obtenus, ils sont appliqués sur des composants de la même famille mais dont les conditions d'utilisation sont rarement celles spécifiées lors de la conception. Un autre inconvénient des modèles de fiabilité est l'absence de surveillance, d'actualisation et de décision en ligne. D'où notre proposition de travailler sur le PHM plutôt que sur la fiabilité. La différence entre PHM et fiabilité pourrait être expliquée par l'analogie entre boucle ouverte et boucle fermée en automatique : le PHM est pour la fiabilité ce que la boucle fermée est pour la boucle ouverte.

Les problématiques du PHM des MEMS restent les mêmes que celles du PHM dans les macro-systèmes, avec cependant les spécificités du micro-monde à considérer. Nos problématiques principales concernent la prédiction de la durée de fonctionnement avant défaillances (pronostic de défaillances) et la décision post-pronostic. Dans cette sous-section, seule la prédiction du RUL est abordée ; la décision sera décrite dans la sous-section suivante. Le pronostic de défaillances des MEMS nécessite la levée de trois verrous que nous avons identifiés : 1) la surveillance des MEMS, 2) la modélisation des MEMS et de leurs mécanismes de dégradation et 3) la définition de seuils de défaillance pertinents.

Concernant la surveillance, et contrairement aux macro-systèmes où l'installation de plusieurs capteurs est possible, l'accès direct par des capteurs aux grandeurs physiques à surveiller peut être difficile, voire parfois impossible à réaliser. Pour contourner cette difficulté, l'une des pistes à envisager pourrait être la mise en place d'observateurs ou de méthodes d'estimation paramétrique.

La modélisation des MEMS et de leurs dégradations n'est pas une tâche aisée. Les MEMS sont des systèmes multiphysiques complexes. Cette tâche nécessite l'étude approfondie du fonctionnement des MEMS, de leurs mécanismes de dégradation, de leurs conditions de sollicitation et des facteurs environnementaux qui peuvent influencer sur le déclenchement des dégradations. Le modèle global d'un MEMS peut être obtenu par la combinaison de son modèle nominal et de son modèle de dégradation. Cette dernière peut être représentée par la dérive dans le temps d'un ou de plusieurs paramètres physiques du MEMS. Pour obtenir le modèle global, l'une des pistes qui pourrait être envisagée est l'utilisation de l'approche hybride. Elle permettra de modéliser le comportement nominal du MEMS par des modèles physiques et d'apprendre le modèle de dégradation à partir de données issues de tests de vieillissement accéléré. Parmi les outils de modélisation candidats, nous pourrions citer les équations différentielles linéaires et non linéaires, les bond graphs, les régressions linéaires et non linéaires et les méthodes par apprentissage automatique. Concernant les tests de vieillissement accéléré, ils seront réalisés sur des plateformes expérimentales qui seront conçues et développées dans nos futurs travaux.

Le modèle global obtenu sera utilisé pour évaluer à tout instant l'état de santé du MEMS et prédire son RUL. Pour cela, il est nécessaire de définir des seuils pertinents permettant d'un côté, de détecter dès les premiers instants l'apparition des dégradations et de l'autre côté, d'estimer le RUL avec précision. Ces seuils peuvent être obtenus par des méthodes statistiques sur des échantillons représentatifs de MEMS, par apprentissage automatique sur des données représentant des modes de fonctionnement normaux et dégradés ou par la définition de limites de performance telle que la précision, la stabilité ou le temps de réponse.

Enfin, pour vérifier et valider nos futurs développements dans ce domaine, nous avons intégré dans notre feuille de route la conception et la réalisation de plateformes expérimentales. Une première version d'une première plateforme est d'ores et déjà réalisée dans le cadre de la thèse de Haithem Skima qui travaille sur la thématique du PHM des MEMS. Elle sera améliorée et complétée par d'autres plateformes pour permettre de couvrir la majeure partie des aspects gravitant autour de cette thématique.

Le lien entre le PHM des macro-systèmes et celui des MEMS n'est pas évident à établir de prime abord. Mais, en analysant de plus près les applications des MEMS, on s'aperçoit qu'elles sont diversifiées et touchent à la majeure partie des systèmes que nous utilisons dans notre quotidien. Quelques-unes de ces applications concernent les moyens de communication (vidéo-projecteurs, microphones, gyroscopes et autres micro-capteurs dans les téléphones portables, résonateurs dans les satellites, etc.) et les systèmes d'aide à la conduite, de confort et de sécurité dans le domaine du transport (accéléromètres pour le déclenchement d'airbags et capteurs de pression dans les voitures, micro-capteurs de température, de vibration, d'humidité, de force et de débit et micro-actionneurs dans les avions, etc.). Les MEMS présents dans ces macro-systèmes assurent des fonctions vitales de surveillance et d'actionnement, et leurs défaillances peuvent rendre indisponibles les macro-systèmes dans lesquels ils sont utilisés et conduire à une indisponibilité du service final attendu par l'utilisateur. Ainsi, les MEMS peuvent se retrouver comme composants critiques et doivent donc être considérés dans le processus de PHM du système global.

2.3 Décision

Comme nous l'avons décrit dans ce mémoire, le PHM comporte sept modules parmi lesquels la décision. Cette dernière intervient après les modules de détection, de diagnostic et de pronostic. Elle a pour rôle de définir les actions à mettre en place pour assurer le maintien en conditions opérationnelles du système physique.

La décision constitue notre troisième perspective de recherche. Elle concerne les deux volets PHM des systèmes complexes et PHM des MEMS. Nous envisageons de mettre en place des algorithmes permettant d'aider l'utilisateur à prendre les meilleures décisions suite à un déclenchement de dégradation, détection et diagnostic de défaillance et pronostic de durées de fonctionnement avant défaillance. Ces algorithmes pourraient prendre différentes formes : optimisation des tâches de maintenance, reconfiguration par l'utilisation de redondances matérielles, modification de consignes ou de lois commande, accommodation des défaillances par des changements de missions, etc.

Nous proposerons également de capitaliser tout ce qui est appris du PHM pour revenir sur la conception et améliorer les versions ultérieures des systèmes à réaliser. En effet, comme le recommande la norme ISO 13381-1, un rapport doit être établi à la fin du processus de pronostic. Il permet d'analyser et de comprendre les causes des anomalies et d'établir des indicateurs de coût, de disponibilité et de sécurité. Il permet également de mettre en place des actions correctrices

en fonction des anomalies ou imperfections constatées. Ces actions peuvent prendre différentes formes : revoir le placement de capteurs ou d'actionneurs pour assurer une surveillance optimale et une meilleure « commandabilité » du système, repositionner ou redimensionner certains composants pour avoir une meilleure « maintenabilité » des composants (accéder facilement aux composants pour une maintenance à moindre coût), améliorer l'interface utilisateur pour mieux informer ce dernier de l'état de santé du système, etc. Le but de ce retour sur conception est de permettre la réalisation de systèmes intelligents et intégrant des fonctionnalités innovantes de PHM telle que l'auto-surveillance, l'auto-détection, l'auto-diagnostic ou encore l'auto-reconfiguration.

2.4 Transferts industriel et académique

Enfin, nous ne pouvons terminer ce document sans aborder le volet transfert qui revêt pour nous une importance particulière. Ce transfert concerne autant le côté industriel que le côté académique.

Pour ce qui est du transfert industriel, nous avons déjà eu et avons toujours des collaborations avec des industriels dans les domaines du transport ferroviaire et des machines à outils. Ces collaborations, réalisées dans le cadre de projets, nous ont permis d'aborder la thématique du PHM avec plus de pragmatisme et en ayant à l'esprit les contraintes applicatives qui ne sont pas toujours prises en compte dans les développements scientifiques. Elles ont également permis aux industriels d'acquérir de nouvelles compétences en maintenances conditionnelle et prédictive, de se mettre au courant des nouvelles innovations dans ces domaines et d'accroître leur compétitivité. Nous souhaitons ainsi continuer ces collaborations pour permettre aux entreprises de concrétiser la mise en œuvre de solutions de PHM dans leurs systèmes. Cela passera par la prise en compte, dans les algorithmes que nous développerons, des différentes spécifications imposées par les industriels (temps de calcul, encombrement, retour sur investissement, etc.). Ce transfert industriel concernera les domaines macro et micro avec des applications diverses : télécommunications, aérospatial, microtechniques et systèmes de génération d'énergie (éoliennes, par exemple) et de transport ferroviaire.

Un autre volet que nous souhaitons développer avec les entreprises concerne la formation continue de leurs cadres de maintenance. Notre objectif est de permettre à ces entreprises d'accroître leur compétitivité en développant des maintenances intelligentes, telle que la maintenance basée sur l'état (Condition-Based Maintenance) et la maintenance prédictive. Ces maintenances pourraient compléter ou remplacer les maintenances traditionnelles de types correctives ou préventives systématiques qui sont souvent coûteuses en disponibilité, en sécurité et en argent.

Pour le volet transfert académique, nous nous fixons comme objectifs l'introduction, le développement, la consolidation et la vulgarisation du PHM dans le milieu académique. Nous avons déjà commencé ce travail par la publication d'un article dans la revue « Techniques de l'Ingénieur » et par la mise en place de cours d'introduction au PHM dans le cadre de l'option « Ingénierie des systèmes de production » de l'ENSMM (troisième année d'école d'ingénieurs). Toutefois, cela n'est pas suffisant et nous envisageons de multiplier nos efforts pour mettre en place de nouveaux cours et travaux pratiques destinés aux étudiants des niveaux licence et master. Nous envisageons également de renforcer notre implication dans la proposition et l'encadrement de stages dans le domaine du PHM. Cela permettra à nos étudiants d'acquérir des compétences nouvelles et innovantes qui sont de plus en plus présentes et demandées dans l'industrie. Enfin, nous mettrons un accent particulier sur la sensibilisation de nos étudiants à jouer un rôle moteur dans l'innovation et à créer leurs entreprises dans le domaine du PHM et de la maintenance intelligente.

Bibliographie

- [1] [http ://www.femto-st.fr/en/research-departments/as2m/research-groups/phm/ieee-phm-2012-data-challenge.php](http://www.femto-st.fr/en/research-departments/as2m/research-groups/phm/ieee-phm-2012-data-challenge.php).
- [2] ISO 281 :2007. Roulements – charges dynamiques de base et durée nominale.
- [3] CEI 60812. Techniques d’analyse de la fiabilité du système - procédure d’analyse des modes de défaillance et de leurs effets (AMDE).
- [4] AFNOR. Condition monitoring and diagnostics of machines - prognostics - part 1 : General guidelines. NF ISO 13381-1, 2005.
- [5] M. Aizerman, E. Braverman, and L. Rozonoer. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control*, 25 :821–837, 1964.
- [6] P.F. Albrecht, J.C. Appiarius, and D.K. Sharma. Assesment of the reliability of motors in utility applications - updated. *IEEE Transactions on Energy Conversion*, EC-1 :39–46, 1986.
- [7] J. B. Allen. Short term spectral analysis, synthesis, and modification by discrete Fourier transform. *IEEE Trans. Acoustics, Speech, Signal Processing*, 25(3) :235–238, 1977.
- [8] J. Antonino-Daviu, S. Aviyente, E.G. Strangas, M. Riera-Guasp, J. Roger-Folch, and R.B. Perez. An EMD-based invariant feature extraction algorithm for rotor bar condition monitoring. In *Proceeding of the IEEE SDEMPED*, pages 669–675, 2011.
- [9] Georges Asch. *Acquisition de données - du capteur à l’ordinateur*. Dunod, 2ème édition edition, 2003.
- [10] P. Baraldi, I. C. Popescu, and E. Zio. Methods of uncertainty analysis in prognostics. *International Journal of Performability Engineering*, 6(4) :303–331, 2010.
- [11] Anne Barros, Christophe Bérenguer, and Antoine Grall. On the hazard rate process for imperfectly monitored multi-unit systems. *Reliability engineering and systems safety*, 90(2-3) :169–176, 2005.
- [12] P. Baruah and R. Chinnam. Hmms for diagnostics and prognostics in machining process. *International journal of Production Research*, 43(6) :1275 – 1293, 2005.
- [13] L. B. Baum. An inequality and associated maximization technique in statistical estimation for probabilistic functions of Markov processes. *Inequalities*, 3 :1–8, 1972.
- [14] L.E. Baum and J.A. Egon. An inequality with applications to statistical estimation for probabilistic functions of a Markov process and to a model for ecology. *Bulletin of the American Mathematical Society*, 73 :360 – 363, 1967.
- [15] M. Bendou and P. Munteanu. Learning bayesian networks from noisy data. In *5th International Conference On Enterprise Information systems (ICEIS)*, 2003.

- [16] T. Benkedjouh, K. Medjaher, N. Zerhouni, and S. Rechak. Health assessment and life prediction of cutting tools based on support vector regression. *Journal of Intelligent Manufacturing*, 2013. Article published online 19 April 2013, DOI 10.1007/s10845-013-0774-6.
- [17] T. Benkedjouh, K. Medjaher, N. Zerhouni, and S. Rechak. Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence*, 26(7) :1751–1760, 2013.
- [18] Younès Bennani. *Systèmes d'apprentissage connexionnistes : sélection de variables*, volume 15. Hermes Science Publications, 2001.
- [19] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006.
- [20] Heinz P. Bloch and Fred K. Geitner. *Machinery failure analysis and troubleshooting*. Elsevier, 1999.
- [21] B. Boashash. Note on the use of the wigner distribution for time frequency signal analysis. *IEEE Trans. Acoustics, Speech and Signal Processing*, 36(9) :1518–1521, 1988.
- [22] B. E. Boser, I. M. Guyon, and V. N. Vapnik. A training algorithm for optimal margin classifiers. In *Fifth Annual Workshop on Computational Learning Theory*, pages 144–152, Pittsburgh, ACM, 1992.
- [23] E.H. Bouchikhi, V. Choqueuse, M.E.H. Benbouzid, J.F. Charpentier, and G. Barakat. A comparative study of time-frequency representations for fault detection in wind turbine. In *Proceeding of the IEEE IECON'2011*, pages 3584–3589, 2011.
- [24] BS 5760-5. Reliability of systems, equipment and components - guide to failure modes, effects and criticality analysis (FMEA and FMECA).
- [25] C. S. Byington, M. J. Roemer, and T. Galie. Prognostic enhancements to diagnostic systems for improved condition-based maintenance. In *IEEE Aerospace Conference*, volume 6, pages 2815 – 2824, Big Sky, USA, 2002.
- [26] F. Cadini, E. Zio, and D. Avram. Model-based monte carlo state estimation for condition-based component replacement. *Reliability Engineering & System Safety*, 94(3) :752 – 758, 2009.
- [27] F. Camci and R.B. Chinnam. Health state estimation and prognostics in machining processes. *IEEE Transactions on Automation Science and Engineering*, 7(3) :581–597, 2010.
- [28] F. Camci, K. Medjaher, , Zerhouni, and P. Nectoux. Feature evaluation for effective bearing prognostics. *Quality and Reliability Engineering International*, 29 :477–486, 2013.
- [29] D. Chelidze and J.P. Cusumano. A dynamical systems approach to failure prognosis. *Journal of Vibration and Acoustics*, 126 :2 – 8, 2004.
- [30] Shunfeng Cheng and Michael Azarian. Sensor system selection for prognostics and health monitoring. In *Proceedings of the ASME 2008 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference*, 2008.
- [31] Ratna Babu Chinnam and Pundarikaksha Baruah. Autonomous diagnostics and prognostics through competitive learning driven hmm-based clustering. In *Proceedings of the International Joint Conference on Neural Networks*, volume 4, pages 2466–2471, 2003.
- [32] Ratna Babu Chinnam and Pundarikaksha Baruah. A neuro-fuzzy approach for estimating mean residual life in condition-based maintenance systems. *International Journal of Materials and Product Technology*, 20 :166 – 179, 2004.
- [33] M. Datig and T. Schlurmann. Performance and limitations of the Hilbert-Huang transformation (HHT) with an application to irregular water waves. *Ocean Engineering*, 31(14-15) :1783–1834, 2004.

- [34] T. Dean and K. Kanazawa. A model for reasoning about persistence and causation. *Artificial Intelligence*, 93(1 - 2) :1 – 27, 1989.
- [35] C. Dellacorte, V. Lukaszewicz, M. Valco, K. C. Radil, and H. Heshmat. Performance and durability of high temperature foil air bearings for oil-free turbomachinery. *Tribology transactions*, 43(4) :774–780, 2000.
- [36] M. Dong and D. He. A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology. *Mechanical Systems and Signal Processing*, 21 :2248 – 2266., 2007.
- [37] Ming Dong and Zhi-bo Yang. Dynamic bayesian network based prognosis in machining processes. *Journal of Shanghai Jiaotong University (Science)*, 13 :318–322, 2008.
- [38] Huseyin Metin Ertunc and Cuneyt Oysu. Drill wear monitoring using cutting force signals. *Mechatronics*, 14(5) :533 – 548, 2004.
- [39] G. Georgoulas, I.P. Tsoumas, J.A. Antonino-Daviu, V. Climente-Alarcon, C.D. Stylios, E.D. Mitronikas, and A.N. Safacas. Automatic pattern identification based on the complex empirical mode decomposition of the startup current for the diagnosis of rotor asymmetries in asynchronous machines. *IEEE Trans. on Industrial Electronics*, 61(9) :4937–4946, 2014.
- [40] Antoine Grall, Laurence Dieulle, Christophe Béranger, and Michel Roussignol. Asymptotic failure rate of a continuous monitored system. *Reliability engineering and systems safety*, 91(2) :126–130, 2006.
- [41] Isabelle Guyon and Andre Elisseeff. An introduction to variable and feature selection. *J. Mach. Learn. Res.*, pages 1157–1182, 2003.
- [42] Isabelle Guyon, Steve Gunn, Masoud Nikravesh, and Lofti A. Zadeh. *Feature Extraction : Foundations and Applications (Studies in Fuzziness and Soft Computing)*. Springer, first edition edition, 2006.
- [43] D. He, L. Ruoyu, and Z. Junda. Plastic bearing fault diagnosis based on a two-step data mining approach. *IEEE Trans. on Industrial Electronics*, 60(8) :3429–3440, 2013.
- [44] A. Heng, S. Zhang, Andy C.C. Tan, and J. Mathew. Rotating machinery prognostics : State of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*, 23(3) :724 – 739, 2009.
- [45] L. Hong and J.S. Dhupia. A time domain approach to diagnose gearbox fault based on measured vibration signals. *Journal of Sound and Vibration*, 333(7) :2164–2180, 2014.
- [46] Sheng Hong, Zheng Zhou, Enrico Zio, and Wenbin Wang. An adaptive method for health trend prediction of rotating bearings. *Digital Signal Processing*, 2014. Article in press.
- [47] N. E. Huang and N. O. Attoh-Okine. *The Hilbert-Huang Transform in Engineering*. CRC Taylor and Francis, 2005. ISBN : 978-0849334221.
- [48] N. E. Huang, S. R. Long, and Z. Shen. The mechanism for frequency downshift in nonlinear wave evolution. *Advances in Applied Mechanics*, 32 :59–111, 1996. 10.1016/S0065-2156(08)70076-0.
- [49] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London Series A : Mathematical, Physical and Engineering Sciences*, pages 903–995, 1998.
- [50] N.E. Huang, Z. Shen, and S. Long. A new view of nonlinear water waves : The Hilbert spectrum. *Annual Review of Fluid Mechanics*, 61 :417–457, 1999.

- [51] Runqing Huang, Lifeng Xi, Xinglin Li, C. Richard Liu, Hai Qiu, and Jay Lee. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods. *Mechanical Systems and Signal Processing*, 21(1) :193 – 207, 2007.
- [52] W. Huang, Z. Shen, N. E. Huang, and Y. C. Fung. Engineering analysis of intrinsic mode and indicial response in biology : the transient response of pulmonary blood pressure to step hypoxia and step recovery. In *Proceeding of the National Academy of Science*, volume 95, pages 12766–12771, 1998.
- [53] W. Huang, Z. Shen, N. E. Huang, and Y. C. Fung. Nonlinear indicial response of complex nonsta-tionary oscillations as pulmonary hypertension responding to step hypoxia. In *Proceeding of the of the National Academy of Sciences*, volume 96, pages 1834–1839, 1999.
- [54] R. Isermann. Supervision : fault-detection and fault-diagnosis methods. an introduction. *Control Engineering Practice*, 5 :639–652, 1997.
- [55] Rolf Isermann. Model-based fault-detection and diagnosis - status and applications. *Annual Reviews in Control*, 29(1) :71 – 85, 2005.
- [56] Andrew. K.S. Jardine, Daming Lin, and Dragan Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7) :1483 – 1510, 2006.
- [57] K. Javed, R. Gouriveau, and N. Zerhouni. SW-ELM : A summation wavelet extreme learning machine algorithm with a priori initialization. *Neurocomputing / EEG Neurocomputing*, 123 :299–307, 2014.
- [58] K. Javed, R. Gouriveau, N. Zerhouni, and P. Nectoux. Enabling health monitoring approach based on vibration data for accurate prognostics. *IEEE Transactions on Industrial Electronics*, pages 1–9, 2014.
- [59] Kamran Javed. *A robust and reliable Data-driven prognostics approach based on extreme learning machine and fuzzy clustering*. PhD thesis, Université de Franche-Comté, 2013.
- [60] R. Jiangtao, C. Yuanwen, and X. Xiaochen. Application of Hilbert-Huang transform and mahalanobis-taguchi system in mechanical fault diagnostics using vibration signals. In *IEEE ICEMI Conference*, volume 4, pages 299–303, 2011.
- [61] I. T. Jolliffe. *Principal Component Analysis*. Springer, 2002.
- [62] B. H. Juang. Maximum likelihood estimation for mixture multivariate stochastic observations of marko chains. *AT&T Technical Journal*, 64 :1235–1249, 1985.
- [63] G.J. Kacprzynski, A. Sarlashkar, M.J. Roemer, A. Hess, and B. Hardman. Predicting remaining life by fusing the physics of failure modeling with diagnostics. *Journal of the Minerals, Metals and Materials Society*, 56 :29–35, 2004.
- [64] Tuncay Karacay and Nizami Akturk. Experimental diagnostics of ballbearings using statistical and spectral methods. *Tribology International*, 42 :836–843, 2009.
- [65] Anne Barros Khanh Le Son, Mitra Fouladirad. Remaining useful life estimation on the non-homogenous gamma with noise deterioration based on gibbs filtering : A case study. In *IEEE-PHM 2012*, Denver, June 2012.
- [66] Racha Khelif, Simon Malinowski, Brigitte Chebel-Morello, and Nouredine Zerhouni. Un-supervised kernel regression modeling approach for rul prediction. In *Second European Conference of the PHM Society*, Nantes, France, 8-10 July 2014.
- [67] Mohamed EL Koujok. *Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou*. PhD thesis, Université de Franche-Comté, 2010.
- [68] S. Kurada and C. Bradley. A review of machine vision sensors for tool condition monitoring. *Computers in Industry*, 34 :55–72, 1997.

- [69] T.R. Kurfess, S. Billington, and S. Liang. Advanced diagnostic and prognostic techniques for rolling element bearings. *Springer Series in Advanced Manufacturing*, pages 137–165, 2006.
- [70] Yves Langeron, Antoine Grall, Anne Barros, and Christophe Berenguer. Residual useful lifetime prognosis and design of control system. In *PSAM ESREL 2012*, Helsinki, June 2012.
- [71] Curtis Lanham. Understanding the tests that are recommended for electric motor predictive maintenance. Technical report, Baker Instrument Company, 2002.
- [72] Mitchell Lebold and Michael Thurston. Open standards for condition-based maintenance and prognostic systems. In *Maintenance and Reliability Conference (MARCON)*, 2001.
- [73] Jay Lee, Jun Ni, Dragan Djurdjanovic, Hai Qiu, and Haitao Liao. Intelligent prognostics tools and e-maintenance. *Computers in Industry*, 57(6) :476 – 489, 2006. E-maintenance Special Issue.
- [74] Jay Lee, Fangji Wu, Wenyu Zhao, Masoud Ghaffari, Linxia Liao, and David Siegel. Prognostics and health management design for rotary machinery systems - reviews, methodology and applications. *Mechanical Systems and Signal Processing*, 42 :314–334, 2014.
- [75] S. W. Lee, J. Park, and S. W. Lee. Low resolution face recognition based on support vector data description. *Pattern Recognition*, 39(9) :1809–1812, 2006.
- [76] B. Li, M.Y. Chow, Y. Tipsuwan, and J.C. Hung. Neural-network-based motor rolling bearing fault diagnosis. *IEEE Trans. Industrial Electronics*, 47(5) :1060–1069, 2000.
- [77] C. J. Li and J. Ma. Wavelet decomposition of vibrations for detection of bearing localized defects. *NDT & E International*, 30(3) :143–149, 1997.
- [78] C.J. Li and S. Choi. Spur gear root fatigue crack prognosis via crack diagnosis and fracture mechanics. In *Proceedings of the 56th Meeting of the Society of Mechanical Failures Prevention Technology*, pages 311 – 320, 2002.
- [79] C.J. Li and H. Lee. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. *Mechanical Systems and Signal Processing*, 19 :836 – 846, 2005.
- [80] Y. Li, S. Billington, C. Zhang, T. Kurfess, S. Danyluk, and S. Liang. Adaptive prognostics for rolling element bearing condition. *Mechanical Systems and Signal Processing*, 13 :103–113, 1999.
- [81] Y. Li, T. R. Kurfess, and S. Y. Liang. Stochastic prognostics for rolling element bearings. *Mechanical Systems and Signal Processing*, 14 :747–762, 2000.
- [82] Y. Li, F. Yingle, L. Gu, and T. Qinye. Sleep stage classification based on eeg Hilbert-Huang transform. In *Proceeding of IEEE ICIEA*, pages 3676–3681, 2009.
- [83] Hu-Chen Liu, Long Liu, and Nan Liu. Risk evaluation approaches in failure mode and effects analysis : A literature review <http://dx.doi.org/10.1016/j.eswa.2012.08.010>. *Expert Systems with Applications*, 40(2) :828–838, 2013.
- [84] C. Lu and X. Hu. A new method of fault diagnosis for high-voltage circuit-breakers based on Hilbert-Huang transform. In *Proceeding of the IEEE ICIEA*, pages 2697–2701, 2007.
- [85] Jianhui Luo, Krishna R. Pattipati, Liu Qiao, and Shunsuke Chigusa. Model-based prognostic techniques applied to a suspension system. *Transactions on Systems, Man, and Cybernetics*, 38 :1156–1168, 2003.
- [86] S. Marble and B. P. Morton. Predicting the remaining life of propulsion system bearings. In *Proceedings of the IEEE Aerospace Conference*, pages 1 – 8, 2006.

- [87] A. Mathur, K. Cavanaugh, K. Pattipati, P. Willet, and T. Galie. Reasoning and modeling systems in diagnosis and prognosis. In *SPIE Aerosense Conference*, 2001.
- [88] G. J. McLachlan and T. Krishnan. *The EM Algorithm and Extensions*. Wiley, 1997.
- [89] K. Medjaher. *Contribution de l'outil bond graph pour la conception de systèmes de supervision des processus industriels*. PhD thesis, Université des Sciences et Technologies de Lille, 2005.
- [90] K. Medjaher, F. Camci, and N. Zerhouni. Feature extraction and evaluation for health assessment and failure prognostics. In *First European Conference of the Prognostics and Health Management Society*, Dresden, Germany, July 3-5 2012.
- [91] K. Medjaher, D.A. Tobon-Mejia, and N. Zerhouni. Remaining useful life estimation of critical components with application to bearings. *IEEE Transactions on Reliability*, pages 292–302, 2012.
- [92] K. Medjaher and N. Zerhouni. Hybrid prognostic method applied to mechatronic systems. *Int. J. Adv. Manuf. Technol.*, 69 :823–834, 2013.
- [93] X. L. Meng and D. van Dyk. The EM algorithm - an old folk song sung to a fast new tune (with discussion). *Journal of royal statistics society*, 59 :511–567, 1997.
- [94] J. Mercer. Functions of positive and negative type and their connection with the theory of integral equations. *Philos. Trans. Roy. Soc. London*, 209(A) :415–446, 1909.
- [95] S Mohanty, A Chattopadhyay, P Peralta, S Das, and C Willhauck. Fatigue life prediction using multivariate gaussian process. In *AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics and materials conference*, Schaumburg, IL, USA, April 2008.
- [96] A. Mosallam, K. Medjaher, and N. Zerhouni. Unsupervised trend extraction for prognostics and condition assessment. In *A-MEST'12, 2nd IFAC workshop on Advanced Maintenance Engineering Service and Technology*, pages 97–102, Seville, Spain, 22 - 23 November 2012.
- [97] A. Mosallam, K. Medjaher, and N. Zerhouni. Nonparametric time series modelling for industrial prognostics and health management. *The International Journal of Advanced Manufacturing Technology*, 6 :1685 – 1699, 2013.
- [98] A. Mosallam, K. Medjaher, and N. Zerhouni. Data-driven prognostic method based on bayesian approaches for direct remaining useful life prediction. *Journal of Intelligent Manufacturing*, 2014. Article published online 13 June 2014, DOI 10.1007/s10845-014-0933-4.
- [99] A. Mosallam, K. Medjaher, and N. Zerhouni. Integrated bayesian framework for remaining useful life prediction. In *IEEE International Conference on Prognostics and Health Management, PHM'2014*, Spokane (WA), USA, June 2014.
- [100] A. Mosallam, K. Medjaher, and N. Zerhouni. Time series trending for condition assessment and prognostics. *Journal of Manufacturing Technology Management*, 25(4) :550–567, 2014.
- [101] Ahmed Mosallam. Self-organized selection of features for unsupervised on-board fault detection. Master's thesis, Orebro university, 2010.
- [102] Ahmed Mosallam. *Contribution to remaining useful life estimation of critical components based on Bayesian approaches*. PhD thesis, Université de Franche-Comté, 2014.
- [103] Alexandre Muller. *Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic*. PhD thesis, Université Henri Poincaré, Nancy I, 2005.
- [104] Murphy. Bayes net toolbox for matlab. In <http://code.google.com/p/bnt/>, 2002.

- [105] Kevin Patrick Murphy. *Dynamic Bayesian Networks : Representation, Inference and learning*. PhD thesis, University of California, 2002.
- [106] P. Nectoux, R. Gouriveau, K. Medjaher, E. Ramasso, B. Chebel-Morello, N. Zerhouni, and C. Varnier. Pronostia : An experimental platform for bearings accelerated degradation tests. In *IEEE International Conference on Prognostics and Health Management, PHM'12, Denver, Colorado, USA*, 2012.
- [107] D.E. Newland. Wavelet analysis of vibration part 1 : Theory. *ASME Journal of Vibration and Acoustics*, 116(4) :409–416, 1994.
- [108] G. Niu and B.-S. Yang. Dempster-Shafer regression for multi-step-ahead time-series prediction towards data-driven machinery prognosis. *Mechanical Systems and Signal Processing*, 23 :740–751, 2009.
- [109] J.C. Nunes, Y. Bouaoune, E. Delechelle, O. Niang, and P. Bunel. Image analysis by bi-dimensional empirical mode decomposition. *Image and Vision Computing*, 21(12) :1019–1026, 2003.
- [110] H. Ocak, K.A. Loparo, and F.M. Discenzo. Online tracking of bearing wear using wavelet packet decomposition and probabilistic modeling : a method for bearing prognostics. *Journal of Sound and Vibration*, 302(4-5) :951–961, 2007.
- [111] P O'Donnell. Report of large motor reliability survey of industrial and commercial installations, part I, II & III. *IEEE Transactions on Industry Applications*, 21 :853–872, 1985.
- [112] M. Orchard, B. Wu, and G. Vachtsevanos. A particle filter framework for failure prognosis. In *Proceedings of the World Tribology Congress*, 2005.
- [113] J. Pearl. *Probabilistic reasoning in intelligent systems : Networks of plausible inference*. Morgan Kaufmann, 1988.
- [114] Y. Peng, M. Dong, and M. J. Zuo. Current status of machine prognostics in condition-based maintenance : a review. *Int. Journal of Advanced Manufacturing Technology*, 50 :297 – 313, 2010.
- [115] Ying Peng and Ming Dong. A prognosis method using age-dependent hidden semi-Markov model for equipment health prediction. *Mechanical Systems and Signal Processing*, 25(1) :237 – 252, 2011.
- [116] Z.K. Peng, P. W. Tse, and F.L. Chu. An improved Hilbert-Huang transform and its application in vibration signal analysis. *Journal of Sound and Vibration*, 286(1-2) :187–205, 2005.
- [117] Flavien PEYSSON. *Contribution au pronostic des systèmes complexes*. PhD thesis, Université Aix-Marseille, 2009.
- [118] E. Phelps, P. Willett, T. Kirubarajan, and C. Brideau. Predicting time to failure using the imm and excitable tests. *IEEE Transactions on Systems, Man and Cybernetics, PartA : Systems and Humans*, 37(5) :630–642, 2007.
- [119] V. Popovic and B. Vasic. Review of hazard analysis methods and their basic characteristics. *FME Transactions*, 4 :181 – 187, 2008.
- [120] G. Provan. Prognosis and condition-based monitoring : an open systems architecture. In *IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, number 5, pages 57–62, 2003.
- [121] K.W. Przytula and A. Choi. An implementation of prognosis with dynamic bayesian networks. In *Aerospace Conference*, 2008.

- [122] Jing Qiu, Cheng Zhang, Brij B. Seth, and Steven Y. Liang. Damage mechanics approach for bearing lifetime prognostics. *Mechanical Systems and Signal Processing*, 12 :817–829, 2002.
- [123] L. R. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition. In *Proceedings of the IEEE*, volume 77 (2), pages 257–286, 1989.
- [124] Carl Edward Rasmussen and Chris Williams. *Gaussian Processes for Machine Learning*. The MIT Press, 2006.
- [125] Qun Ren, Marek Balazinski, Luc Baron, and Krzysztof Jemielniak. TSK fuzzy modeling for tool wear condition in turning processes : An experimental study. *Engineering Applications of Artificial Intelligence*, 24(2) :260 – 265, 2001.
- [126] B. Saha and K. Goebel. Battery data set, NASA AMES prognostics data repository <http://ti.arc.nasa.gov/project/prognostic-data-repository>], 2007, NASA AMES, Moffett field, CA., 2007.
- [127] A. Saxena and K. Goebel. C-MAPSS data set, NASA AMES prognostics data repository, [<http://ti.arc.nasa.gov/project/prognostic-data-repository>], 2008, NASA AMES, Moffett field, CA.
- [128] Abhinav Saxena, Jose Celaya, Bhaskar Saha, Sankalita Saha, and Kai Goebel. Metrics for offline evaluation of prognostic performance. *International Journal of Prognostics and Health Management*, 2010.
- [129] Lisa Serir. *Méthodes de pronostic basées sur les fonctions de croyance*. PhD thesis, Université de Franche-Comté, 2012.
- [130] Y.-T. Sheen. On the study of applying morlet wavelet to the Hilbert transform for the envelope detection of bearing vibrations. *Mechanical Systems and Signal Processing*, 23(5) :1518–1527, 2009.
- [131] J.Z. Sikorska, M Hodkiewicz, and L Ma. Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5) :1803–1836, 2011.
- [132] Bassel Solaiman. *Processus stochastiques pour l'ingénieur*. Presses polytechniques et universitaires romandes, 2006.
- [133] Khanh Le Son, Mitra Fouladirad, Anne Barros, Eric Levrat, and Benoît Iung. Remaining useful life estimation based on stochastic deterioration models : A comparative study. *Reliability Engineering and System Safety*, 112 :165 – 175, 2013.
- [134] A. Soualhi, K. Medjaher, and N. Zerhouni. Bearing health monitoring based on Hilbert-Huang transform, support vector machine and regression. *IEEE Transactions on Instrumentation and Measurement*, 2014. Article published online 01 July 2014, DOI : 10.1109/TIM.2014.2330494.
- [135] D. J. Spiegelhalter and S. L. Lauritzen. Sequential updating of conditional probabilities on directed graphical structures. *Networks*, 20, 1990.
- [136] J.R. Stack, R.G. Harley, and T.G. Habetler. An amplitude modulation detector for fault diagnosis in rolling element bearings. *IEEE Trans. on Industrial Electronics*, 51(5) :1097–1102, 2004.
- [137] M. Subrahmanyam and C. Sujatha. Using neural networks for the diagnosis of localized defects in ball bearings. *Tribology International*, 30(10) :739–752, 1997.
- [138] David C. Swanson, J. Michael Spencer, and Sevag H. Arzoumanian. Prognostic modelling of crack growth in a tensioned steel band. *Mechanical systems and signal processing*, 14 :789–803, 1999.

- [139] D.C. Swanson. A general prognostic tracking algorithm for predictive maintenance. In *IEEE Aerospace Conference*, pages 2971–2977, Big Sky, MT, USA, 2001.
- [140] N. Tandon. A comparison of some vibration parameters for the condition monitoring of rolling element bearings. *Measurement*, 12 :285–289, 1994.
- [141] J.B. Tenenbaum, V. De Silva, and J. C. Langford. A global geometric framework for nonlinear dimensionality reduction. *Science*, 290 :2319 – 2323, 2000.
- [142] A.K. Samantaray and B. Ould Bouamama. *Model-Based Process Supervision : A Bond Graph Approach*. Springer, 2008.
- [143] The NASA’s Prognostics Center of Excellence. Prognostic data repository, <http://ti.arc.nasa.gov/tech/dash/pcoe/prognostic-data-repository/>, visited in July 2014.
- [144] NSF I/UCRC Center for Intelligent Maintenance Systems. Prognostic data repository : Bearing data set. In <http://ti.arc.nasa.gov/tech/dash/pcoe/prognostic-data-repository/>, online in 2010.
- [145] PHM Society. PHM data challenge 2010. In <https://www.phmsociety.org/competition/phm/10>, 2010.
- [146] D. A. Tobon-Mejia. *Contribution au pronostic industriel de défaillances guidé par les données : approche Bayésienne appliquée aux composants des moteurs électriques*. PhD thesis, Université de Franche-Comté, 2011.
- [147] D. A. Tobon-Mejia, K. Medjaher, and N. Zerhouni. CNC machine tool health assessment using dynamic bayesian networks. In *IFAC World Congress*, 2011.
- [148] D. A. Tobon-Mejia, K. Medjaher, and N. Zerhouni. CNC machine tool’s wear diagnostic and prognostic by using dynamic bayesian networks. *Mechanical Systems and Signal Processing*, 28 :167 – 182, 2012.
- [149] D. A. Tobon-Mejia, Kamal Medjaher, Nouredine Zerhouni, and Gerard Tripot. A mixture of gaussians hidden Markov model for failure diagnostic and prognostic. In *IEEE Conference on Automation Science and Engineering, CASE’10*, 2010.
- [150] D.A. Tobon-Mejia, K. Medjaher, N. Zerhouni, and G Tripot. A data-driven failure prognostics method based on mixture of gaussians hidden Markov models. *IEEE Transactions on Reliability*, pages 491–503, 2012.
- [151] Diego Tobon-Mejia, Kamal Medjaher, Nouredine Zerhouni, and Gerard Tripot. Estimation of the remaining useful life by using wavelet packet decomposition and HMMS. In *IEEE Aerospace Conference*, 2011.
- [152] Diego A. Tobon-Mejia, Kamal Medjaher, and Nouredine Zerhouni. Hidden Markov models for failure diagnostic and prognostic. In *IEEE - Prognostics & System Health Management Conference*, Shenzhen, China, 21 - 23 March 2011.
- [153] P. Tse and D. Atherton. Prediction of machine deterioration using vibration based fault trends and recurrent neural networks. *Transactions of the ASME : Journal of Vibration and Acoustics*, 121 :355 – 362, 1999.
- [154] G. Vachtsevanos and P. Wang. Fault prognosis using dynamic wavelet neural networks. In *IEEE System Readiness Technology Conference, Autotestcon Proceedings*, 2001.
- [155] George Vachtsevanos, Frank L. Lewis, Michael Roemer, Andrew Hess, and Biqing Wu. *Intelligent fault diagnosis and prognosis for engineering systems*. Wiley, 2006.
- [156] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer, New York, 1995.
- [157] Venkat Venkatasubramanian. Prognostic and diagnostic monitoring of complex systems for product lifecycle management : Challenges and opportunities. *Computers & Chemical Engineering*, 29(6) :1253 – 1263, 2005.

- [158] Alain Villemeur. *Sûreté de fonctionnement des systèmes industriels*. Eyrolles, 1988.
- [159] A.J. Viterbi. Error bounds for convolutional codes and an asymptotically optimal decoding algorithm. *IEEE Transaction on Information Theory*, 13 :260 – 269, 1967.
- [160] Yvan Vérot. Retour d’expérience dans les industries de procédé. In *Conception et Production*. Techniques de l’ingénieur, 2001.
- [161] L. Wang, C. Koblinsky, S. Howden, and N. E. Huang. Inter annual variability in the south china sea from expendable bathythermograph data. *Journal of Geophysical Research*, 104(10) :23509–23523, 1999.
- [162] P. Wang and G. Vachtsevanos. Fault prognosis using dynamic wavelet neural networks. In *Maintennace and reliability conference (MARCON 99)*, 1999.
- [163] W. Wang. An adaptive predictor for dynamic system forecasting. *Mechanical Systems and Signal Processing*, 21 :809 – 823, 2007.
- [164] Wilson Q. Wang, M. Farid Golnaraghi, and Fathy Ismail. Prognosis of machine health condition using neuro-fuzzy systems. *Mechanical Systems and Signal Processing*, 18(4) :813 – 831, 2004.
- [165] W.J. Wang and P.D. McFadden. Application of wavelets to gearbox vibration signal for fault detection. *Journal of Sound and Vibration*, 192(5) :927–939, 1996.
- [166] M. L. Wu, S. Schubert, and N. E. Huang. The development of the south asian summer monsoon and the intraseasonal oscillation. *Journal of Climate*, 12(7) :2054–2075, 1999.
- [167] W. Wu, J. Hu, and J. Zhang. Prognostics of machine health condition using animproved arima-based prediction method. In *IEEE China*, pages 1062–1067, Harbin, China, 2007.
- [168] R.C.M. Yam, P.W. Tse, L. Li, and P. Tu. Intelligent predictive decision support system for CBM. *The International Journal of Advanced Manufacturing Technology*, 17 :383 – 391, 2001.
- [169] J. Yan, M. Koc, and J. Lee. A prognostic algorithm for machine performance assessment and its application. *Production Planning and Control* ., 76 :796–801, 2004.
- [170] R. Yan and R. X. Gao. Multi-scale enveloping spectrogram for vibration analysis in bearing defect diagnosis. *Tribology International*, 42(2) :293–302, 2009.
- [171] W. Yan, H. Qiu, and N. Iyer. Feature extraction for bearing prognostics and health management (PHM)-a survey. Technical report, Air Force Research Laboratory, 2008.
- [172] G.Y. Yen and K.C. Lin. Wavelet packet feature extraction for vibration monitoring. In *In Proceedings of IEEE International Conference on Control Applications*, pages 1573–1578, 1999.
- [173] Jafar Zarei and Javad Poshtan. Bearing fault detection using wavelet packet transform of induction motor stator current. *Tribology International*, 40(5) :763 – 769, 2007.
- [174] Junhong Zhou, Xiang Li, Oon Peen Gan, Shuguo Han, and Wee Keong Ng. Genetic algorithms for feature subset selection in equipment fault diagnostics. *Journal of Engineering asset management*, 10 :1104–1113, 2006.
- [175] E. Zio and F. D. Maio. A data-driven fuzzy approach for predicting the remaining useful life in dynamic failure scenarios of a nuclear system. *Reliability Engieneering and System Safety*, 95 :49 – 57, 2010.
- [176] Enrico Zio, Francesco Di Maio, and Marco Stasi. A data-driven approach for predicting failure scenarios in nuclear systems. *Annals of Nuclear Energy*, 37 :482–491, 2010.